
Grenzen der Quantifizierung operationeller Risiken

Christof Reese



Köln 2007

Grenzen der Quantifizierung operationeller Risiken

Christof Reese

Dissertation

an der Fakultät für Mathematik, Informatik und Statistik

der Ludwig-Maximilians-Universität

München

vorgelegt von

Christof Reese

aus Köln

München, den 10.04.2007

Erstgutachter: Prof. Stefan Mittnik, Ph.D.

Zweitgutachter: Prof. Dr. Ludwig Fahrmeir

Tag der mündlichen Prüfung: 07.11.2007

FÜR MARGOT

Danksagung

Ich bedanke mich bei meinem Betreuer, Herrn Prof. Mittnik sowie bei den beiden weiteren Gutachtern, Herrn Prof. Fahrmeir und Herrn Prof. Missong. Dann bedanke ich mich bei Herrn Prof. Leisch und Herrn Prof. Küchenhoff für die Durchführung des Rigorosums.

Weiterhin bedanke ich mich bei Herrn Bodo Schmidt dafür, dass er mir eine Promotionsstelle gegeben hat sowie bei Herrn Dr. Thomas Kaiser für seine fachliche Unterstützung.

Schließlich bedanke ich mich bei meinen Eltern sowie bei meiner Frau Dé-bora, die mich zur jeder Zeit unterstützt hat und ohne die ich diese Arbeit vermutlich niemals hätte fertig stellen können.

Christof Reese

im November 2007

Zusammenfassung

In hoch entwickelten Wirtschaftssystemen unterliegen Banken einer besonderen Beaufsichtigung, da ein gut funktionierendes Finanzsystem die Grundlage einer soliden Wirtschaft darstellt. Insbesondere sind Banken verpflichtet, eine gesetzlich vorgegebene Eigenkapitaluntergrenze einzuhalten. Diese Grenze wurde in der Vergangenheit im Wesentlichen durch die Höhe der Bilanzaktiva bestimmt. Banken mussten für die aus diesen Positionen resultierenden Kredit- und Marktrisiken Eigenkapital vorhalten. Übrige Risiken wurden nur implizit abgedeckt. Durch die neue Baseler Eigenkapitalvereinbarung, die eine Empfehlung eines Ausschusses von Vertretern der Zentralbanken der großen Industrienationen darstellt und zurzeit in die jeweiligen nationalen Rechte umgesetzt wird, sollen nun unter anderem zusätzlich operationelle Risiken explizit mit Eigenkapital hinterlegt werden müssen.

Zur Berechnung des notwendigen Eigenkapitals werden in der Vereinbarung drei verschiedene Ansätze aufgeführt, von denen zwei lediglich einfache und vermutlich risikounabhängige Berechnungsvorschriften darstellen; der dritte Ansatz jedoch – der Advanced Measurement Approach – kann bei entsprechender Ausgestaltung risikosensitiv sein, da er die Entwicklung und Verwen-

dung selbst entwickelter Verfahren zur Bestimmung des Kapitals gestattet.

Typischerweise werden bei solchen Verfahren Methoden aus der Versicherungswirtschaft verwendet, die Fragen zu Risiken von Prozessen, Personen, Technologie und externen Ereignissen bereits seit längerer Zeit zu beantworten versucht. Dazu werden die Ursachen der in der Vergangenheit aufgetretenen Verluste analysiert, um die aktuelle Gefahr zukünftiger Verluste zu ermitteln.

Bei der Quantifizierung von Risiken in Banken müssen sehr hohe Quantile bestimmt werden, damit sichergestellt ist, dass das Unternehmen mit großer Wahrscheinlichkeit nicht zahlungsunfähig wird. Dies ist auch bei operationellen Risiken der Fall. Im Gegensatz zu Markt- oder Kreditrisiken stehen jedoch bei diesen nur relativ wenige Daten zur Verfügung. Dennoch wird in vielen zur Zeit verwendeten Modellen die Sensitivität der Ergebnisse aufgrund dieser sehr geringen Datenbasis nicht oder nicht ausreichend berücksichtigt.

Die vorliegende Arbeit stellt ein Verfahren vor, um Konfidenzintervalle für geschätzte typische Risikogrößen wie z.B. einen Value-at-Risk oder den Expected Shortfall zu ermitteln. Die Anwendung wird dann anhand beispielhaft generierter Daten dargestellt, wobei die spezifischen Eigenheiten operationeller Risiken berücksichtigt werden. Dabei zeigt es sich, dass die bestimmten Konfidenzintervalle – abhängig von der für die Schätzungen verwendbaren Daten – mehrere Größenordnungen umfassen können. Bei der Interpretation der Daten und der daraus folgenden endgültigen Bestimmung von Mindestkapitalanforderungen für operationelle Risiken bei Banken müssen dann derartige Unschärfen berücksichtigt werden.

Abstract

A good working financial system is the basis for a solid economy. Therefore in highly developed economies financial institutions are especially supervised. In particular banks are required to keep a certain amount of equity determined by national authorities. Under the rules of Basel I this amount was determined mainly by the value of assets. Banks were required to keep equity for market and credit risks. Other risks were only covered implicitly. In the new Basel capital accord also operational risk has to be covered with equity explicitly. To calculate the necessary equity the accord mentions three approaches the basic indicator approach, the standardized approach and advanced measurement approach. Only the latter – the advanced measurement approach – is intended to have some risk sensitivity. It allows the application of self developed models to measure the necessary equity.

The typical model to quantify operational risks is based on models from insurances. Insurances already gained some expertise to quantify risks resulting from persons, processes, technology or external events. Data from history are extrapolated to predict future risks.

To quantify risks in banks it is necessary to calculate a high quantile of the loss distribution. This is necessary to ensure that the bank is not going to become illiquid. The same is true for operational risk. But in opposite to other risks like market or credit risks for the calculation of operational risks there are usually only few data available. Despite this problem for most of the models mentioned in literature the problem of sensitivity of the results is not mentioned appropriately.

This thesis shows a method to calculate confidence intervals for risk measures like the value-at-risk or the expected shortfall. The application of this method is shown with simulated data. The specific features of operational risk are taken into account. It is shown that the confidence intervals can include several orders of magnitude. To interpret the data and to finally calculate the necessary equity these fuzziness has to be taken into account to ensure the survival of the bank even if high impact losses occur.

Inhaltsverzeichnis

Danksagung	vii
Zusammenfassung	ix
Abstract	xi
Abbildungsverzeichnis	xvii
Tabellenverzeichnis	xxxi

I. Hintergrund und Theorie	1
1. Einleitung und Überblick	3
2. Operationelle Risiken in Basel II	7
2.1. Entwicklung von Basel II	9
2.2. Definition und Abgrenzung	11
2.3. Risikokategorien und Business Lines	14
2.3.1. Business Lines nach Basel II	14
2.3.2. Risikokategorien nach Basel II	16
2.3.3. Berücksichtigung von Abhängigkeiten	20
2.4. Quantitative Informationsquellen	20
2.4.1. Interne Verlustdaten	21
2.4.2. Externe Verlustdaten aus öffentlichen Quellen	26
2.4.3. Externe Verlustdaten aus Datenkonsortien	28
2.5. Sonstige Daten	30
2.5.1. Risk-Assessment	30
2.5.2. Risikoindikatoren	32
2.5.3. Szenarioanalysen	34
2.5.4. Beinaheverluste	36
2.5.5. Hilfsdaten	37
2.6. Berechnungsansätze	39

2.6.1.	Basisindikatoransatz	39
2.6.2.	Standardansatz	40
2.6.3.	Ambitionierte Messansätze	42
3.	Quantifizierung operationeller Risiken – typische Modellierungsansätze	45
3.1.	Value-at-Risk	46
3.2.	Expected Shortfall	47
3.3.	Verlustverteilungsansatz	48
3.3.1.	Bezeichnungen	49
3.3.2.	Verlusthäufigkeit	50
3.3.3.	Verlusthöhe	51
3.3.4.	Gesamtverlust	55
3.4.	Bayesianische Schätzverfahren	56
3.4.1.	Der Satz von Bayes	56
3.4.2.	Bayesianische Verlusthäufigkeit	58
3.4.3.	Bayesianische Verlusthöhe	59
3.5.	Monte-Carlo-Simulation	61
4.	Güte der Berechnungen	63
4.1.	Normalverteilte Verluste	64
4.2.	Nicht-parametrische Verfahren	65
4.3.	Monte-Carlo-Simulation	66
II.	Simulation	69
5.	Die „doppelte Monte-Carlo-Simulation“	71
6.	Simulationsergebnisse	75
6.1.	Annahmen	76
6.2.	Technische Informationen	78
6.3.	Modelle ohne Berücksichtigung von A-Priori-Informationen	79
6.3.1.	Modell Lognormal–Lognormal	80
6.3.2.	Modell Lognormal–Pareto	88
6.3.3.	Modell Lognormal–Weibull	95
6.3.4.	Modell Lognormal–Gamma	102
6.3.5.	Modell Lognormal–Mischung	108
6.4.	Modell unter Berücksichtigung von A-Priori-Informationen	116
6.4.1.	Modell Bayes–hochgewichtet	117
6.4.2.	Modell Bayes–niedriggewichtet	123
6.5.	Zusammenfassung der Ergebnisse	128

7. Schlussbetrachtung	131
A. Modell Lognormal-Lognormal	137
B. Modell Lognormal-Pareto	157
C. Modell Lognormal-Weibull	177
D. Modell Lognormal-Gamma	197
E. Modell Lognormal-Mischung	217
F. Modell Bayes–hochgewichtet	237
G. Modell Bayes–niedriggewichtet	243
Literaturverzeichnis	249

Abbildungsverzeichnis

6.1. Modell Log-Log, Parameterausprägung A1, Ermittlung des tatsächlichen OpVaR	82
6.2. Modell Log-Log, Parameterausprägung A1, Ermittlung des tatsächlichen ES	83
6.3. Modell Log-Log, Parameterausprägung A1, Schwankungen des OpVaR .	85
6.4. Modell Log-Log, Parameterausprägung A1, Schwankungen des ES	86
6.5. Modell Log-Par, Parameterausprägung A1, Ermittlung des tatsächlichen OpVaR	90
6.6. Modell Log-Par, Parameterausprägung A1, Ermittlung des tatsächlichen ES	91
6.7. Modell Log-Par, Parameterausprägung A1, Schwankungen des OpVaR .	92
6.8. Modell Log-Par, Parameterausprägung A1, Schwankungen des ES	93
6.9. Modell Log-Wei, Parameterausprägung A1, Ermittlung des tatsächlichen OpVaR	97
6.10. Modell Log-Wei, Parameterausprägung A1, Ermittlung des tatsächlichen ES	98
6.11. Modell Log-Wei, Parameterausprägung A1, Schwankungen des OpVaR .	99
6.12. Modell Log-Wei, Parameterausprägung A1, Schwankungen des ES	100
6.13. Modell Log-Gam, Parameterausprägung A1, Ermittlung des tatsächlichen OpVaR	103
6.14. Modell Log-Gam, Parameterausprägung A1, Ermittlung des tatsächlichen ES	104
6.15. Modell Log-Gam, Parameterausprägung A1, Schwankungen des OpVaR .	105
6.16. Modell Log-Gam, Parameterausprägung A1, Schwankungen des ES . . .	106
6.17. Modell Log-Mis, Parameterausprägung A1, Ermittlung des tatsächlichen OpVaR	110
6.18. Modell Log-Mis, Parameterausprägung A1, Ermittlung des tatsächlichen ES	111
6.19. Modell Log-Mis, Parameterausprägung A1, Schwankungen des OpVaR .	114
6.20. Modell Log-Mis, Parameterausprägung A1, Schwankungen des ES	115
6.21. Modell BayHoch, Schwankungen des OpVaR bei unterschätzenden A-Priori-Parametern	119

6.22. Modell BayHoch, Schwankungen des OpVaR bei korrekten A-Priori-Parametern	120
6.23. Modell BayHoch, Schwankungen des OpVaR bei überschätzenden A-Priori-Parametern	121
6.24. Modell BayNiedrig, Schwankungen des OpVaR bei unterschätzenden A-Priori-Parametern	124
6.25. Modell BayNiedrig, Schwankungen des OpVaR bei korrekten A-Priori-Parametern	125
6.26. Modell BayNiedrig, Schwankungen des OpVaR bei überschätzenden A-Priori-Parametern	126
A.1. Modell LogLog, Ergebnis A1, VaR, Wahrer Wert	139
A.2. Modell LogLog, Ergebnis A1, VaR	139
A.3. Modell LogLog, Ergebnis A1, ES, Wahrer Wert	139
A.4. Modell LogLog, Ergebnis A1, ES	139
A.5. Modell LogLog, Ergebnis A2, VaR, Wahrer Wert	140
A.6. Modell LogLog, Ergebnis A2, VaR	140
A.7. Modell LogLog, Ergebnis A2, ES, Wahrer Wert	140
A.8. Modell LogLog, Ergebnis A2, ES	140
A.9. Modell LogLog, Ergebnis A3, VaR, Wahrer Wert	140
A.10. Modell LogLog, Ergebnis A3, VaR	140
A.11. Modell LogLog, Ergebnis A3, ES, Wahrer Wert	141
A.12. Modell LogLog, Ergebnis A3, ES	141
A.13. Modell LogLog, Ergebnis A4, VaR, Wahrer Wert	141
A.14. Modell LogLog, Ergebnis A4, VaR	141
A.15. Modell LogLog, Ergebnis A4, ES, Wahrer Wert	141
A.16. Modell LogLog, Ergebnis A4, ES	141
A.17. Modell LogLog, Ergebnis A5, VaR, Wahrer Wert	142
A.18. Modell LogLog, Ergebnis A5, VaR	142
A.19. Modell LogLog, Ergebnis A5, ES, Wahrer Wert	142
A.20. Modell LogLog, Ergebnis A5, ES	142
A.21. Modell LogLog, Ergebnis A6, VaR, Wahrer Wert	142
A.22. Modell LogLog, Ergebnis A6, VaR	142
A.23. Modell LogLog, Ergebnis A6, ES, Wahrer Wert	143
A.24. Modell LogLog, Ergebnis A6, ES	143
A.25. Modell LogLog, Ergebnis B1, VaR, Wahrer Wert	143
A.26. Modell LogLog, Ergebnis B1, VaR	143
A.27. Modell LogLog, Ergebnis B1, ES, Wahrer Wert	144
A.28. Modell LogLog, Ergebnis B1, ES	144
A.29. Modell LogLog, Ergebnis B2, VaR, Wahrer Wert	144
A.30. Modell LogLog, Ergebnis B2, VaR	144
A.31. Modell LogLog, Ergebnis B2, ES, Wahrer Wert	144

A.32.Modell LogLog, Ergebnis B2, ES	144
A.33.Modell LogLog, Ergebnis B3, VaR, Wahrer Wert	145
A.34.Modell LogLog, Ergebnis B3, VaR	145
A.35.Modell LogLog, Ergebnis B3, ES, Wahrer Wert	145
A.36.Modell LogLog, Ergebnis B3, ES	145
A.37.Modell LogLog, Ergebnis B4, VaR, Wahrer Wert	145
A.38.Modell LogLog, Ergebnis B4, VaR	145
A.39.Modell LogLog, Ergebnis B4, ES, Wahrer Wert	146
A.40.Modell LogLog, Ergebnis B4, ES	146
A.41.Modell LogLog, Ergebnis B5, VaR, Wahrer Wert	146
A.42.Modell LogLog, Ergebnis B5, VaR	146
A.43.Modell LogLog, Ergebnis B5, ES, Wahrer Wert	146
A.44.Modell LogLog, Ergebnis B5, ES	146
A.45.Modell LogLog, Ergebnis B6, VaR, Wahrer Wert	147
A.46.Modell LogLog, Ergebnis B6, VaR	147
A.47.Modell LogLog, Ergebnis B6, ES, Wahrer Wert	147
A.48.Modell LogLog, Ergebnis B6, ES	147
A.49.Modell LogLog, Ergebnis C1, VaR, Wahrer Wert	148
A.50.Modell LogLog, Ergebnis C1, VaR	148
A.51.Modell LogLog, Ergebnis C1, ES, Wahrer Wert	148
A.52.Modell LogLog, Ergebnis C1, ES	148
A.53.Modell LogLog, Ergebnis C2, VaR, Wahrer Wert	148
A.54.Modell LogLog, Ergebnis C2, VaR	148
A.55.Modell LogLog, Ergebnis C2, ES, Wahrer Wert	149
A.56.Modell LogLog, Ergebnis C2, ES	149
A.57.Modell LogLog, Ergebnis C3, VaR, Wahrer Wert	149
A.58.Modell LogLog, Ergebnis C3, VaR	149
A.59.Modell LogLog, Ergebnis C3, ES, Wahrer Wert	149
A.60.Modell LogLog, Ergebnis C3, ES	149
A.61.Modell LogLog, Ergebnis C4, VaR, Wahrer Wert	150
A.62.Modell LogLog, Ergebnis C4, VaR	150
A.63.Modell LogLog, Ergebnis C4, ES, Wahrer Wert	150
A.64.Modell LogLog, Ergebnis C4, ES	150
A.65.Modell LogLog, Ergebnis C5, VaR, Wahrer Wert	150
A.66.Modell LogLog, Ergebnis C5, VaR	150
A.67.Modell LogLog, Ergebnis C5, ES, Wahrer Wert	151
A.68.Modell LogLog, Ergebnis C5, ES	151
A.69.Modell LogLog, Ergebnis C6, VaR, Wahrer Wert	151
A.70.Modell LogLog, Ergebnis C6, VaR	151
A.71.Modell LogLog, Ergebnis C6, ES, Wahrer Wert	151
A.72.Modell LogLog, Ergebnis C6, ES	151
A.73.Modell LogLog, Ergebnis D1, VaR, Wahrer Wert	152

A.74.Modell LogLog, Ergebnis D1, VaR	152
A.75.Modell LogLog, Ergebnis D1, ES, Wahrer Wert	152
A.76.Modell LogLog, Ergebnis D1, ES	152
A.77.Modell LogLog, Ergebnis D2, VaR, Wahrer Wert	153
A.78.Modell LogLog, Ergebnis D2, VaR	153
A.79.Modell LogLog, Ergebnis D2, ES, Wahrer Wert	153
A.80.Modell LogLog, Ergebnis D2, ES	153
A.81.Modell LogLog, Ergebnis D3, VaR, Wahrer Wert	153
A.82.Modell LogLog, Ergebnis D3, VaR	153
A.83.Modell LogLog, Ergebnis D3, ES, Wahrer Wert	154
A.84.Modell LogLog, Ergebnis D3, ES	154
A.85.Modell LogLog, Ergebnis D4, VaR, Wahrer Wert	154
A.86.Modell LogLog, Ergebnis D4, VaR	154
A.87.Modell LogLog, Ergebnis D4, ES, Wahrer Wert	154
A.88.Modell LogLog, Ergebnis D4, ES	154
A.89.Modell LogLog, Ergebnis D5, VaR, Wahrer Wert	155
A.90.Modell LogLog, Ergebnis D5, VaR	155
A.91.Modell LogLog, Ergebnis D5, ES, Wahrer Wert	155
A.92.Modell LogLog, Ergebnis D5, ES	155
A.93.Modell LogLog, Ergebnis D6, VaR, Wahrer Wert	155
A.94.Modell LogLog, Ergebnis D6, VaR	155
A.95.Modell LogLog, Ergebnis D6, ES, Wahrer Wert	156
A.96.Modell LogLog, Ergebnis D6, ES	156
 B.1. Modell LogPar, Ergebnis A1, VaR, Wahrer Wert	 159
B.2. Modell LogPar, Ergebnis A1, VaR	159
B.3. Modell LogPar, Ergebnis A1, ES, Wahrer Wert	159
B.4. Modell LogPar, Ergebnis A1, ES	159
B.5. Modell LogPar, Ergebnis A2, VaR, Wahrer Wert	159
B.6. Modell LogPar, Ergebnis A2, VaR	159
B.7. Modell LogPar, Ergebnis A2, ES, Wahrer Wert	160
B.8. Modell LogPar, Ergebnis A2, ES	160
B.9. Modell LogPar, Ergebnis A3, VaR, Wahrer Wert	160
B.10.Modell LogPar, Ergebnis A3, VaR	160
B.11.Modell LogPar, Ergebnis A3, ES, Wahrer Wert	160
B.12.Modell LogPar, Ergebnis A3, ES	160
B.13.Modell LogPar, Ergebnis A4, VaR, Wahrer Wert	161
B.14.Modell LogPar, Ergebnis A4, VaR	161
B.15.Modell LogPar, Ergebnis A4, ES, Wahrer Wert	161
B.16.Modell LogPar, Ergebnis A4, ES	161
B.17.Modell LogPar, Ergebnis A5, VaR, Wahrer Wert	161
B.18.Modell LogPar, Ergebnis A5, VaR	161

B.19.Modell LogPar, Ergebnis A5, ES, Wahrer Wert	162
B.20.Modell LogPar, Ergebnis A5, ES	162
B.21.Modell LogPar, Ergebnis A6, VaR, Wahrer Wert	162
B.22.Modell LogPar, Ergebnis A6, VaR	162
B.23.Modell LogPar, Ergebnis A6, ES, Wahrer Wert	162
B.24.Modell LogPar, Ergebnis A6, ES	162
B.25.Modell LogPar, Ergebnis B1, VaR, Wahrer Wert	163
B.26.Modell LogPar, Ergebnis B1, VaR	163
B.27.Modell LogPar, Ergebnis B1, ES, Wahrer Wert	163
B.28.Modell LogPar, Ergebnis B1, ES	163
B.29.Modell LogPar, Ergebnis B2, VaR, Wahrer Wert	164
B.30.Modell LogPar, Ergebnis B2, VaR	164
B.31.Modell LogPar, Ergebnis B2, ES, Wahrer Wert	164
B.32.Modell LogPar, Ergebnis B2, ES	164
B.33.Modell LogPar, Ergebnis B3, VaR, Wahrer Wert	164
B.34.Modell LogPar, Ergebnis B3, VaR	164
B.35.Modell LogPar, Ergebnis B3, ES, Wahrer Wert	165
B.36.Modell LogPar, Ergebnis B3, ES	165
B.37.Modell LogPar, Ergebnis B4, VaR, Wahrer Wert	165
B.38.Modell LogPar, Ergebnis B4, VaR	165
B.39.Modell LogPar, Ergebnis B4, ES, Wahrer Wert	165
B.40.Modell LogPar, Ergebnis B4, ES	165
B.41.Modell LogPar, Ergebnis B5, VaR, Wahrer Wert	166
B.42.Modell LogPar, Ergebnis B5, VaR	166
B.43.Modell LogPar, Ergebnis B5, ES, Wahrer Wert	166
B.44.Modell LogPar, Ergebnis B5, ES	166
B.45.Modell LogPar, Ergebnis B6, VaR, Wahrer Wert	166
B.46.Modell LogPar, Ergebnis B6, VaR	166
B.47.Modell LogPar, Ergebnis B6, ES, Wahrer Wert	167
B.48.Modell LogPar, Ergebnis B6, ES	167
B.49.Modell LogPar, Ergebnis C1, VaR, Wahrer Wert	167
B.50.Modell LogPar, Ergebnis C1, VaR	167
B.51.Modell LogPar, Ergebnis C1, ES, Wahrer Wert	168
B.52.Modell LogPar, Ergebnis C1, ES	168
B.53.Modell LogPar, Ergebnis C2, VaR, Wahrer Wert	168
B.54.Modell LogPar, Ergebnis C2, VaR	168
B.55.Modell LogPar, Ergebnis C2, ES, Wahrer Wert	168
B.56.Modell LogPar, Ergebnis C2, ES	168
B.57.Modell LogPar, Ergebnis C3, VaR, Wahrer Wert	169
B.58.Modell LogPar, Ergebnis C3, VaR	169
B.59.Modell LogPar, Ergebnis C3, ES, Wahrer Wert	169
B.60.Modell LogPar, Ergebnis C3, ES	169

B.61.Modell LogPar, Ergebnis C4, VaR, Wahrer Wert	169
B.62.Modell LogPar, Ergebnis C4, VaR	169
B.63.Modell LogPar, Ergebnis C4, ES, Wahrer Wert	170
B.64.Modell LogPar, Ergebnis C4, ES	170
B.65.Modell LogPar, Ergebnis C5, VaR, Wahrer Wert	170
B.66.Modell LogPar, Ergebnis C5, VaR	170
B.67.Modell LogPar, Ergebnis C5, ES, Wahrer Wert	170
B.68.Modell LogPar, Ergebnis C5, ES	170
B.69.Modell LogPar, Ergebnis C6, VaR, Wahrer Wert	171
B.70.Modell LogPar, Ergebnis C6, VaR	171
B.71.Modell LogPar, Ergebnis C6, ES, Wahrer Wert	171
B.72.Modell LogPar, Ergebnis C6, ES	171
B.73.Modell LogPar, Ergebnis D1, VaR, Wahrer Wert	172
B.74.Modell LogPar, Ergebnis D1, VaR	172
B.75.Modell LogPar, Ergebnis D1, ES, Wahrer Wert	172
B.76.Modell LogPar, Ergebnis D1, ES	172
B.77.Modell LogPar, Ergebnis D2, VaR, Wahrer Wert	172
B.78.Modell LogPar, Ergebnis D2, VaR	172
B.79.Modell LogPar, Ergebnis D2, ES, Wahrer Wert	173
B.80.Modell LogPar, Ergebnis D2, ES	173
B.81.Modell LogPar, Ergebnis D3, VaR, Wahrer Wert	173
B.82.Modell LogPar, Ergebnis D3, VaR	173
B.83.Modell LogPar, Ergebnis D3, ES, Wahrer Wert	173
B.84.Modell LogPar, Ergebnis D3, ES	173
B.85.Modell LogPar, Ergebnis D4, VaR, Wahrer Wert	174
B.86.Modell LogPar, Ergebnis D4, VaR	174
B.87.Modell LogPar, Ergebnis D4, ES, Wahrer Wert	174
B.88.Modell LogPar, Ergebnis D4, ES	174
B.89.Modell LogPar, Ergebnis D5, VaR, Wahrer Wert	174
B.90.Modell LogPar, Ergebnis D5, VaR	174
B.91.Modell LogPar, Ergebnis D5, ES, Wahrer Wert	175
B.92.Modell LogPar, Ergebnis D5, ES	175
B.93.Modell LogPar, Ergebnis D6, VaR, Wahrer Wert	175
B.94.Modell LogPar, Ergebnis D6, VaR	175
B.95.Modell LogPar, Ergebnis D6, ES, Wahrer Wert	175
B.96.Modell LogPar, Ergebnis D6, ES	175
C.1. Modell LogWei, Ergebnis A1, VaR, Wahrer Wert	179
C.2. Modell LogWei, Ergebnis A1, VaR	179
C.3. Modell LogWei, Ergebnis A1, ES, Wahrer Wert	179
C.4. Modell LogWei, Ergebnis A1, ES	179
C.5. Modell LogWei, Ergebnis A2, VaR, Wahrer Wert	179

C.6. Modell LogWei, Ergebnis A2, VaR	179
C.7. Modell LogWei, Ergebnis A2, ES, Wahrer Wert	180
C.8. Modell LogWei, Ergebnis A2, ES	180
C.9. Modell LogWei, Ergebnis A3, VaR, Wahrer Wert	180
C.10. Modell LogWei, Ergebnis A3, VaR	180
C.11. Modell LogWei, Ergebnis A3, ES, Wahrer Wert	180
C.12. Modell LogWei, Ergebnis A3, ES	180
C.13. Modell LogWei, Ergebnis A4, VaR, Wahrer Wert	181
C.14. Modell LogWei, Ergebnis A4, VaR	181
C.15. Modell LogWei, Ergebnis A4, ES, Wahrer Wert	181
C.16. Modell LogWei, Ergebnis A4, ES	181
C.17. Modell LogWei, Ergebnis A5, VaR, Wahrer Wert	181
C.18. Modell LogWei, Ergebnis A5, VaR	181
C.19. Modell LogWei, Ergebnis A5, ES, Wahrer Wert	182
C.20. Modell LogWei, Ergebnis A5, ES	182
C.21. Modell LogWei, Ergebnis A6, VaR, Wahrer Wert	182
C.22. Modell LogWei, Ergebnis A6, VaR	182
C.23. Modell LogWei, Ergebnis A6, ES, Wahrer Wert	182
C.24. Modell LogWei, Ergebnis A6, ES	182
C.25. Modell LogWei, Ergebnis B1, VaR, Wahrer Wert	183
C.26. Modell LogWei, Ergebnis B1, VaR	183
C.27. Modell LogWei, Ergebnis B1, ES, Wahrer Wert	183
C.28. Modell LogWei, Ergebnis B1, ES	183
C.29. Modell LogWei, Ergebnis B2, VaR, Wahrer Wert	184
C.30. Modell LogWei, Ergebnis B2, VaR	184
C.31. Modell LogWei, Ergebnis B2, ES, Wahrer Wert	184
C.32. Modell LogWei, Ergebnis B2, ES	184
C.33. Modell LogWei, Ergebnis B3, VaR, Wahrer Wert	184
C.34. Modell LogWei, Ergebnis B3, VaR	184
C.35. Modell LogWei, Ergebnis B3, ES, Wahrer Wert	185
C.36. Modell LogWei, Ergebnis B3, ES	185
C.37. Modell LogWei, Ergebnis B4, VaR, Wahrer Wert	185
C.38. Modell LogWei, Ergebnis B4, VaR	185
C.39. Modell LogWei, Ergebnis B4, ES, Wahrer Wert	185
C.40. Modell LogWei, Ergebnis B4, ES	185
C.41. Modell LogWei, Ergebnis B5, VaR, Wahrer Wert	186
C.42. Modell LogWei, Ergebnis B5, VaR	186
C.43. Modell LogWei, Ergebnis B5, ES, Wahrer Wert	186
C.44. Modell LogWei, Ergebnis B5, ES	186
C.45. Modell LogWei, Ergebnis B6, VaR, Wahrer Wert	186
C.46. Modell LogWei, Ergebnis B6, VaR	186
C.47. Modell LogWei, Ergebnis B6, ES, Wahrer Wert	187

C.48.Modell LogWei, Ergebnis B6, ES	187
C.49.Modell LogWei, Ergebnis C1, VaR, Wahrer Wert	187
C.50.Modell LogWei, Ergebnis C1, VaR	187
C.51.Modell LogWei, Ergebnis C1, ES, Wahrer Wert	188
C.52.Modell LogWei, Ergebnis C1, ES	188
C.53.Modell LogWei, Ergebnis C2, VaR, Wahrer Wert	188
C.54.Modell LogWei, Ergebnis C2, VaR	188
C.55.Modell LogWei, Ergebnis C2, ES, Wahrer Wert	188
C.56.Modell LogWei, Ergebnis C2, ES	188
C.57.Modell LogWei, Ergebnis C3, VaR, Wahrer Wert	189
C.58.Modell LogWei, Ergebnis C3, VaR	189
C.59.Modell LogWei, Ergebnis C3, ES, Wahrer Wert	189
C.60.Modell LogWei, Ergebnis C3, ES	189
C.61.Modell LogWei, Ergebnis C4, VaR, Wahrer Wert	189
C.62.Modell LogWei, Ergebnis C4, VaR	189
C.63.Modell LogWei, Ergebnis C4, ES, Wahrer Wert	190
C.64.Modell LogWei, Ergebnis C4, ES	190
C.65.Modell LogWei, Ergebnis C5, VaR, Wahrer Wert	190
C.66.Modell LogWei, Ergebnis C5, VaR	190
C.67.Modell LogWei, Ergebnis C5, ES, Wahrer Wert	190
C.68.Modell LogWei, Ergebnis C5, ES	190
C.69.Modell LogWei, Ergebnis C6, VaR, Wahrer Wert	191
C.70.Modell LogWei, Ergebnis C6, VaR	191
C.71.Modell LogWei, Ergebnis C6, ES, Wahrer Wert	191
C.72.Modell LogWei, Ergebnis C6, ES	191
C.73.Modell LogWei, Ergebnis D1, VaR, Wahrer Wert	192
C.74.Modell LogWei, Ergebnis D1, VaR	192
C.75.Modell LogWei, Ergebnis D1, ES, Wahrer Wert	192
C.76.Modell LogWei, Ergebnis D1, ES	192
C.77.Modell LogWei, Ergebnis D2, VaR, Wahrer Wert	192
C.78.Modell LogWei, Ergebnis D2, VaR	192
C.79.Modell LogWei, Ergebnis D2, ES, Wahrer Wert	193
C.80.Modell LogWei, Ergebnis D2, ES	193
C.81.Modell LogWei, Ergebnis D3, VaR, Wahrer Wert	193
C.82.Modell LogWei, Ergebnis D3, VaR	193
C.83.Modell LogWei, Ergebnis D3, ES, Wahrer Wert	193
C.84.Modell LogWei, Ergebnis D3, ES	193
C.85.Modell LogWei, Ergebnis D4, VaR, Wahrer Wert	194
C.86.Modell LogWei, Ergebnis D4, VaR	194
C.87.Modell LogWei, Ergebnis D4, ES, Wahrer Wert	194
C.88.Modell LogWei, Ergebnis D4, ES	194
C.89.Modell LogWei, Ergebnis D5, VaR, Wahrer Wert	194

C.90.Modell LogWei, Ergebnis D5, VaR	194
C.91.Modell LogWei, Ergebnis D5, ES, Wahrer Wert	195
C.92.Modell LogWei, Ergebnis D5, ES	195
C.93.Modell LogWei, Ergebnis D6, VaR, Wahrer Wert	195
C.94.Modell LogWei, Ergebnis D6, VaR	195
C.95.Modell LogWei, Ergebnis D6, ES, Wahrer Wert	195
C.96.Modell LogWei, Ergebnis D6, ES	195
D.1. Modell LogGam, Ergebnis A1, VaR, Wahrer Wert	199
D.2. Modell LogGam, Ergebnis A1, VaR	199
D.3. Modell LogGam, Ergebnis A1, ES, Wahrer Wert	199
D.4. Modell LogGam, Ergebnis A1, ES	199
D.5. Modell LogGam, Ergebnis A2, VaR, Wahrer Wert	200
D.6. Modell LogGam, Ergebnis A2, VaR	200
D.7. Modell LogGam, Ergebnis A2, ES, Wahrer Wert	200
D.8. Modell LogGam, Ergebnis A2, ES	200
D.9. Modell LogGam, Ergebnis A3, VaR, Wahrer Wert	200
D.10.Modell LogGam, Ergebnis A3, VaR	200
D.11.Modell LogGam, Ergebnis A3, ES, Wahrer Wert	201
D.12.Modell LogGam, Ergebnis A3, ES	201
D.13.Modell LogGam, Ergebnis A4, VaR, Wahrer Wert	201
D.14.Modell LogGam, Ergebnis A4, VaR	201
D.15.Modell LogGam, Ergebnis A4, ES, Wahrer Wert	201
D.16.Modell LogGam, Ergebnis A4, ES	201
D.17.Modell LogGam, Ergebnis A5, VaR, Wahrer Wert	202
D.18.Modell LogGam, Ergebnis A5, VaR	202
D.19.Modell LogGam, Ergebnis A5, ES, Wahrer Wert	202
D.20.Modell LogGam, Ergebnis A5, ES	202
D.21.Modell LogGam, Ergebnis A6, VaR, Wahrer Wert	202
D.22.Modell LogGam, Ergebnis A6, VaR	202
D.23.Modell LogGam, Ergebnis A6, ES, Wahrer Wert	203
D.24.Modell LogGam, Ergebnis A6, ES	203
D.25.Modell LogGam, Ergebnis B1, VaR, Wahrer Wert	203
D.26.Modell LogGam, Ergebnis B1, VaR	203
D.27.Modell LogGam, Ergebnis B1, ES, Wahrer Wert	204
D.28.Modell LogGam, Ergebnis B1, ES	204
D.29.Modell LogGam, Ergebnis B2, VaR, Wahrer Wert	204
D.30.Modell LogGam, Ergebnis B2, VaR	204
D.31.Modell LogGam, Ergebnis B2, ES, Wahrer Wert	204
D.32.Modell LogGam, Ergebnis B2, ES	204
D.33.Modell LogGam, Ergebnis B3, VaR, Wahrer Wert	205
D.34.Modell LogGam, Ergebnis B3, VaR	205

D.35.Modell LogGam, Ergebnis B3, ES, Wahrer Wert	205
D.36.Modell LogGam, Ergebnis B3, ES	205
D.37.Modell LogGam, Ergebnis B4, VaR, Wahrer Wert	205
D.38.Modell LogGam, Ergebnis B4, VaR	205
D.39.Modell LogGam, Ergebnis B4, ES, Wahrer Wert	206
D.40.Modell LogGam, Ergebnis B4, ES	206
D.41.Modell LogGam, Ergebnis B5, VaR, Wahrer Wert	206
D.42.Modell LogGam, Ergebnis B5, VaR	206
D.43.Modell LogGam, Ergebnis B5, ES, Wahrer Wert	206
D.44.Modell LogGam, Ergebnis B5, ES	206
D.45.Modell LogGam, Ergebnis B6, VaR, Wahrer Wert	207
D.46.Modell LogGam, Ergebnis B6, VaR	207
D.47.Modell LogGam, Ergebnis B6, ES, Wahrer Wert	207
D.48.Modell LogGam, Ergebnis B6, ES	207
D.49.Modell LogGam, Ergebnis C1, VaR, Wahrer Wert	208
D.50.Modell LogGam, Ergebnis C1, VaR	208
D.51.Modell LogGam, Ergebnis C1, ES, Wahrer Wert	208
D.52.Modell LogGam, Ergebnis C1, ES	208
D.53.Modell LogGam, Ergebnis C2, VaR, Wahrer Wert	208
D.54.Modell LogGam, Ergebnis C2, VaR	208
D.55.Modell LogGam, Ergebnis C2, ES, Wahrer Wert	209
D.56.Modell LogGam, Ergebnis C2, ES	209
D.57.Modell LogGam, Ergebnis C3, VaR, Wahrer Wert	209
D.58.Modell LogGam, Ergebnis C3, VaR	209
D.59.Modell LogGam, Ergebnis C3, ES, Wahrer Wert	209
D.60.Modell LogGam, Ergebnis C3, ES	209
D.61.Modell LogGam, Ergebnis C4, VaR, Wahrer Wert	210
D.62.Modell LogGam, Ergebnis C4, VaR	210
D.63.Modell LogGam, Ergebnis C4, ES, Wahrer Wert	210
D.64.Modell LogGam, Ergebnis C4, ES	210
D.65.Modell LogGam, Ergebnis C5, VaR, Wahrer Wert	210
D.66.Modell LogGam, Ergebnis C5, VaR	210
D.67.Modell LogGam, Ergebnis C5, ES, Wahrer Wert	211
D.68.Modell LogGam, Ergebnis C5, ES	211
D.69.Modell LogGam, Ergebnis C6, VaR, Wahrer Wert	211
D.70.Modell LogGam, Ergebnis C6, VaR	211
D.71.Modell LogGam, Ergebnis C6, ES, Wahrer Wert	211
D.72.Modell LogGam, Ergebnis C6, ES	211
D.73.Modell LogGam, Ergebnis D1, VaR, Wahrer Wert	212
D.74.Modell LogGam, Ergebnis D1, VaR	212
D.75.Modell LogGam, Ergebnis D1, ES, Wahrer Wert	212
D.76.Modell LogGam, Ergebnis D1, ES	212

D.77.Modell LogGam, Ergebnis D2, VaR, Wahrer Wert	213
D.78.Modell LogGam, Ergebnis D2, VaR	213
D.79.Modell LogGam, Ergebnis D2, ES, Wahrer Wert	213
D.80.Modell LogGam, Ergebnis D2, ES	213
D.81.Modell LogGam, Ergebnis D3, VaR, Wahrer Wert	213
D.82.Modell LogGam, Ergebnis D3, VaR	213
D.83.Modell LogGam, Ergebnis D3, ES, Wahrer Wert	214
D.84.Modell LogGam, Ergebnis D3, ES	214
D.85.Modell LogGam, Ergebnis D4, VaR, Wahrer Wert	214
D.86.Modell LogGam, Ergebnis D4, VaR	214
D.87.Modell LogGam, Ergebnis D4, ES, Wahrer Wert	214
D.88.Modell LogGam, Ergebnis D4, ES	214
D.89.Modell LogGam, Ergebnis D5, VaR, Wahrer Wert	215
D.90.Modell LogGam, Ergebnis D5, VaR	215
D.91.Modell LogGam, Ergebnis D5, ES, Wahrer Wert	215
D.92.Modell LogGam, Ergebnis D5, ES	215
D.93.Modell LogGam, Ergebnis D6, VaR, Wahrer Wert	215
D.94.Modell LogGam, Ergebnis D6, VaR	215
D.95.Modell LogGam, Ergebnis D6, ES, Wahrer Wert	216
D.96.Modell LogGam, Ergebnis D6, ES	216
E.1. Modell LogMis, Ergebnis A1, VaR, Wahrer Wert	219
E.2. Modell LogMis, Ergebnis A1, VaR	219
E.3. Modell LogMis, Ergebnis A1, ES, Wahrer Wert	219
E.4. Modell LogMis, Ergebnis A1, ES	219
E.5. Modell LogMis, Ergebnis A2, VaR, Wahrer Wert	220
E.6. Modell LogMis, Ergebnis A2, VaR	220
E.7. Modell LogMis, Ergebnis A2, ES, Wahrer Wert	220
E.8. Modell LogMis, Ergebnis A2, ES	220
E.9. Modell LogMis, Ergebnis A3, VaR, Wahrer Wert	220
E.10.Modell LogMis, Ergebnis A3, VaR	220
E.11.Modell LogMis, Ergebnis A3, ES, Wahrer Wert	221
E.12.Modell LogMis, Ergebnis A3, ES	221
E.13.Modell LogMis, Ergebnis A4, VaR, Wahrer Wert	221
E.14.Modell LogMis, Ergebnis A4, VaR	221
E.15.Modell LogMis, Ergebnis A4, ES, Wahrer Wert	221
E.16.Modell LogMis, Ergebnis A4, ES	221
E.17.Modell LogMis, Ergebnis A5, VaR, Wahrer Wert	222
E.18.Modell LogMis, Ergebnis A5, VaR	222
E.19.Modell LogMis, Ergebnis A5, ES, Wahrer Wert	222
E.20.Modell LogMis, Ergebnis A5, ES	222
E.21.Modell LogMis, Ergebnis A6, VaR, Wahrer Wert	222

E.22. Modell LogMis, Ergebnis A6, VaR	222
E.23. Modell LogMis, Ergebnis A6, ES, Wahrer Wert	223
E.24. Modell LogMis, Ergebnis A6, ES	223
E.25. Modell LogMis, Ergebnis B1, VaR, Wahrer Wert	223
E.26. Modell LogMis, Ergebnis B1, VaR	223
E.27. Modell LogMis, Ergebnis B1, ES, Wahrer Wert	224
E.28. Modell LogMis, Ergebnis B1, ES	224
E.29. Modell LogMis, Ergebnis B2, VaR, Wahrer Wert	224
E.30. Modell LogMis, Ergebnis B2, VaR	224
E.31. Modell LogMis, Ergebnis B2, ES, Wahrer Wert	224
E.32. Modell LogMis, Ergebnis B2, ES	224
E.33. Modell LogMis, Ergebnis B3, VaR, Wahrer Wert	225
E.34. Modell LogMis, Ergebnis B3, VaR	225
E.35. Modell LogMis, Ergebnis B3, ES, Wahrer Wert	225
E.36. Modell LogMis, Ergebnis B3, ES	225
E.37. Modell LogMis, Ergebnis B4, VaR, Wahrer Wert	225
E.38. Modell LogMis, Ergebnis B4, VaR	225
E.39. Modell LogMis, Ergebnis B4, ES, Wahrer Wert	226
E.40. Modell LogMis, Ergebnis B4, ES	226
E.41. Modell LogMis, Ergebnis B5, VaR, Wahrer Wert	226
E.42. Modell LogMis, Ergebnis B5, VaR	226
E.43. Modell LogMis, Ergebnis B5, ES, Wahrer Wert	226
E.44. Modell LogMis, Ergebnis B5, ES	226
E.45. Modell LogMis, Ergebnis B6, VaR, Wahrer Wert	227
E.46. Modell LogMis, Ergebnis B6, VaR	227
E.47. Modell LogMis, Ergebnis B6, ES, Wahrer Wert	227
E.48. Modell LogMis, Ergebnis B6, ES	227
E.49. Modell LogMis, Ergebnis C1, VaR, Wahrer Wert	228
E.50. Modell LogMis, Ergebnis C1, VaR	228
E.51. Modell LogMis, Ergebnis C1, ES, Wahrer Wert	228
E.52. Modell LogMis, Ergebnis C1, ES	228
E.53. Modell LogMis, Ergebnis C2, VaR, Wahrer Wert	228
E.54. Modell LogMis, Ergebnis C2, VaR	228
E.55. Modell LogMis, Ergebnis C2, ES, Wahrer Wert	229
E.56. Modell LogMis, Ergebnis C2, ES	229
E.57. Modell LogMis, Ergebnis C3, VaR, Wahrer Wert	229
E.58. Modell LogMis, Ergebnis C3, VaR	229
E.59. Modell LogMis, Ergebnis C3, ES, Wahrer Wert	229
E.60. Modell LogMis, Ergebnis C3, ES	229
E.61. Modell LogMis, Ergebnis C4, VaR, Wahrer Wert	230
E.62. Modell LogMis, Ergebnis C4, VaR	230
E.63. Modell LogMis, Ergebnis C4, ES, Wahrer Wert	230

E.64. Modell LogMis, Ergebnis C4, ES	230
E.65. Modell LogMis, Ergebnis C5, VaR, Wahrer Wert	230
E.66. Modell LogMis, Ergebnis C5, VaR	230
E.67. Modell LogMis, Ergebnis C5, ES, Wahrer Wert	231
E.68. Modell LogMis, Ergebnis C5, ES	231
E.69. Modell LogMis, Ergebnis C6, VaR, Wahrer Wert	231
E.70. Modell LogMis, Ergebnis C6, VaR	231
E.71. Modell LogMis, Ergebnis C6, ES, Wahrer Wert	231
E.72. Modell LogMis, Ergebnis C6, ES	231
E.73. Modell LogMis, Ergebnis D1, VaR, Wahrer Wert	232
E.74. Modell LogMis, Ergebnis D1, VaR	232
E.75. Modell LogMis, Ergebnis D1, ES, Wahrer Wert	232
E.76. Modell LogMis, Ergebnis D1, ES	232
E.77. Modell LogMis, Ergebnis D2, VaR, Wahrer Wert	233
E.78. Modell LogMis, Ergebnis D2, VaR	233
E.79. Modell LogMis, Ergebnis D2, ES, Wahrer Wert	233
E.80. Modell LogMis, Ergebnis D2, ES	233
E.81. Modell LogMis, Ergebnis D3, VaR, Wahrer Wert	233
E.82. Modell LogMis, Ergebnis D3, VaR	233
E.83. Modell LogMis, Ergebnis D3, ES, Wahrer Wert	234
E.84. Modell LogMis, Ergebnis D3, ES	234
E.85. Modell LogMis, Ergebnis D4, VaR, Wahrer Wert	234
E.86. Modell LogMis, Ergebnis D4, VaR	234
E.87. Modell LogMis, Ergebnis D4, ES, Wahrer Wert	234
E.88. Modell LogMis, Ergebnis D4, ES	234
E.89. Modell LogMis, Ergebnis D5, VaR, Wahrer Wert	235
E.90. Modell LogMis, Ergebnis D5, VaR	235
E.91. Modell LogMis, Ergebnis D5, ES, Wahrer Wert	235
E.92. Modell LogMis, Ergebnis D5, ES	235
E.93. Modell LogMis, Ergebnis D6, VaR, Wahrer Wert	235
E.94. Modell LogMis, Ergebnis D6, VaR	235
E.95. Modell LogMis, Ergebnis D6, ES, Wahrer Wert	236
E.96. Modell LogMis, Ergebnis D6, ES	236
F.1. Modell BayHoch, Ergebnis A1AA, VaR	238
F.2. Modell BayHoch, Ergebnis A1AB, VaR	238
F.3. Modell BayHoch, Ergebnis A1AC, VaR	239
F.4. Modell BayHoch, Ergebnis A1BA, VaR	239
F.5. Modell BayHoch, Ergebnis A1BB, VaR	240
F.6. Modell BayHoch, Ergebnis A1BC, VaR	240
F.7. Modell BayHoch, Ergebnis A1CA, VaR	241
F.8. Modell BayHoch, Ergebnis A1CB, VaR	241

F.9. Modell BayHoch, Ergebnis A1CC, VaR	242
G.1. Modell BayNiedrig, Ergebnis A1AA, VaR	244
G.2. Modell BayNiedrig, Ergebnis A1AB, VaR	244
G.3. Modell BayNiedrig, Ergebnis A1AC, VaR	245
G.4. Modell BayNiedrig, Ergebnis A1BA, VaR	245
G.5. Modell BayNiedrig, Ergebnis A1BB, VaR	246
G.6. Modell BayNiedrig, Ergebnis A1BC, VaR	246
G.7. Modell BayNiedrig, Ergebnis A1CA, VaR	247
G.8. Modell BayNiedrig, Ergebnis A1CB, VaR	247
G.9. Modell BayNiedrig, Ergebnis A1CC, VaR	248

Tabellenverzeichnis

2.1. Zuordnung der Business Lines nach Basel II	15
2.2. Risikokategorien – Detaillierte Klassifikation nach Basel II	18
2.3. Geschäftsfelder	41
6.1. Modell Log-Log, Modellspezifikation	81
6.2. Modell Log-Log, Parameter der Höhenverteilung	81
6.3. Modell Log-Log, Übersicht über die tatsächlichen OpVaR	84
6.4. Modell Log-Log, Übersicht über die tatsächlichen ES	84
6.5. Modell Log-Log, Übersicht über die Konfidenzintervalle für die OpVaR .	87
6.6. Modell Log-Log, Übersicht über die Konfidenzintervalle für die ES	87
6.7. Modell Log-Par, Modellspezifikation	88
6.8. Modell Log-Par, Parameter der Höhenverteilung	89
6.9. Modell Log-Par, Übersicht über die tatsächlichen OpVaR	90
6.10. Modell Log-Par, Übersicht über die tatsächlichen ES	91
6.11. Modell Log-Par, Übersicht über die Konfidenzintervalle für die OpVaR .	94
6.12. Modell Log-Par, Übersicht über die Konfidenzintervalle für die ES	94
6.13. Modell Log-Wei, Modellspezifikation	95
6.14. Modell Log-Wei, Parameter der Höhenverteilung	96
6.15. Modell Log-Wei, Übersicht über die tatsächlichen OpVaR	96
6.16. Modell Log-Wei, Übersicht über die tatsächlichen OpVaR	96
6.17. Modell Log-Wei, Übersicht über die Konfidenzintervalle für die OpVaR .	101
6.18. Modell Log-Wei, Übersicht über die Konfidenzintervalle für die ES	101
6.19. Modell Log-Gam, Modellspezifikation	102
6.20. Modell Log-Gam, Parameter der Höhenverteilung	102
6.21. Modell Log-Gam, Übersicht über die tatsächlichen OpVaR	103
6.22. Modell Log-Gam, Übersicht über die tatsächlichen ES	104
6.23. Modell Log-Gam, Übersicht über die Konfidenzintervalle für die OpVaR	107
6.24. Modell Log-Gam, Übersicht über die Konfidenzintervalle für die ES . . .	107
6.25. Modell Log-Mis, Modellspezifikation	108
6.26. Modell Log-Mis, Parameter der Höhenverteilung	109
6.27. Modell Log-Mis, Übersicht über die tatsächlichen OpVaR	110
6.28. Modell Log-Mis, Übersicht über die tatsächlichen ES	111

6.29. Modell Log–Mis, Übersicht über die Konfidenzintervalle für die OpVaR	112
6.30. Modell Log–Mis, Übersicht über die Konfidenzintervalle für die ES	113
6.31. Modell BayHoch, Modellspezifikation	118
6.32. Modell BayHoch, Übersicht über die Konfidenzintervalle für den OpVaR	122
6.33. Modell BayNiedrig, Modellspezifikation	123
6.34. Modell BayNiedrig, Übersicht über die Konfidenzintervalle für den OpVaR	127
A.1. Modellspezifikation Modelltyp LogLog	137
A.2. tatsächliche Werte VaR Modelltyp LogLog	137
A.3. tatsächliche Werte ES Modelltyp LogLog	138
A.4. Übersicht über die relativen Fehler VaR, Modelltyp LogLog	138
A.5. Übersicht über die relativen Fehler ES, Modelltyp LogLog	138
A.6. Parameter der Lognormalverteilung, Modelltyp LogLog	138
B.1. Modellspezifikation Modelltyp LogPar	157
B.2. tatsächliche Werte VaR Modelltyp LogPar	157
B.3. tatsächliche Werte ES Modelltyp LogPar	158
B.4. Übersicht über die relativen Fehler VaR, Modelltyp LogPar	158
B.5. Übersicht über die relativen Fehler ES, Modelltyp LogPar	158
B.6. Parameter der Lognormalverteilung, Modelltyp LogPar	158
C.1. Modellspezifikation Modelltyp LogWei	177
C.2. tatsächliche Werte VaR Modelltyp LogWei	177
C.3. tatsächliche Werte ES Modelltyp LogWei	178
C.4. Übersicht über die relativen Fehler VaR, Modelltyp LogWei	178
C.5. Übersicht über die relativen Fehler ES, Modelltyp LogWei	178
C.6. Parameter der Lognormalverteilung, Modelltyp LogWei	178
D.1. Modellspezifikation Modelltyp LogGam	197
D.2. tatsächliche Werte VaR Modelltyp LogGam	197
D.3. tatsächliche Werte ES Modelltyp LogGam	198
D.4. Übersicht über die relativen Fehler VaR, Modelltyp LogGam	198
D.5. Übersicht über die relativen Fehler ES, Modelltyp LogGam	198
D.6. Parameter der Lognormalverteilung, Modelltyp LogGam	198
E.1. Modellspezifikation Modelltyp LogMis	217
E.2. tatsächliche Werte VaR Modelltyp LogMis	217
E.3. tatsächliche Werte ES Modelltyp LogMis	218
E.4. Übersicht über die relativen Fehler VaR, Modelltyp LogMis	218
E.5. Übersicht über die relativen Fehler ES, Modelltyp LogMis	218
E.6. Parameter der Lognormalverteilung, Modelltyp LogMis	218
F.1. Modellspezifikation Modelltyp BayHoch	237

F.2. Übersicht über die relativen Fehler VaR, Modelltyp BayHoch	237
G.1. Modellspezifikation Modelltyp BayNiedrig	243
G.2. Übersicht über die relativen Fehler VaR, Modelltyp BayNiedrig	243

Teil I.

Hintergrund und Theorie

1. Einleitung und Überblick

Für viele der spektakulärsten Verluste von Unternehmen in den vergangenen Jahren waren operationelle Risiken verantwortlich. Als bekannteste Beispiele sind hier der Ruin der Barings Bank, des Long Term Capital Management (LTCM) Fonds oder die Skandale um Flowtex oder Parmalat zu nennen. Schon heute halten Banken einen Teil ihres Eigenkapitals für diese Risiken vor. Im Gegensatz zum Markt- oder Kreditrisikobereich hat sich bei der Identifizierung, Quantifizierung und Steuerung des operationellen Risikos noch kein Industriestandard herausgebildet (Boos und Schulte-Mattler 2001). Weiterhin ist das Bewusstsein für die Notwendigkeit einer systematischen Analyse der Gefahren aus operationellen Risiken in Banken bis auf wenige Ausnahmen erst äußerst schwach ausgeprägt. Auch aus bankaufsichtsrechtlicher Sicht wird operationellen Risiken erst seit 1995 mit Einführung der „Mindestanforderungen an das Betreiben von Handelsgeschäften der Kreditinstitute“ (MaH) (MaH 1995) Bedeutung beigemessen. Dort werden operationelle Risiken noch unter dem Stichwort „Betriebsrisiken“ erwähnt und lediglich qualitative Anforderungen festgelegt.

Bei Aktien- und Kreditgeschäften hat sich eine risikoadjustierte Betrachtung eines Portfolios bzw. des Kreditnehmers bereits durchgesetzt. Im Gegensatz dazu muss sich eine solche Vorgehensweise bei der Betrachtung operationeller Risiken erst noch etablieren. Dies wird sich 2007 mit dem Inkrafttreten von Basel II intensivieren¹. Die Steuerung des

¹für das Folgende vgl. Basel Committee on Banking Supervision (2004)

gesamten Risikoprofils einer Bank inklusive aller Risikoarten rückt dort in den Vordergrund. Basel II ist auf drei Säulen, den Mindestkapitalanforderungen, dem aufsichtlichen Überprüfungsverfahren sowie der Marktdisziplin aufgebaut, die in ihrem Zusammenspiel die Handlungsfähigkeit von Banken sicherstellen sollen. In der ersten Säule, die die Notwendigkeit zur quantitativen Betrachtung auch operationeller Risiken betont, wird es für Banken möglich sein, zwischen einfachen und fortschrittlichen, risikosensitiveren Ansätzen zur Risikoberechnung zu wählen. Damit kann durch von der Aufsicht zu genehmigende interne Modelle die notwendige, aufsichtsrechtliche Eigenkapitalunterlegung beeinflusst und gegebenenfalls gegenüber den einfacheren Ansätzen gesenkt werden. Zu diesem Zweck werden z.Zt. in vielen Banken Modelle entwickelt, die es ermöglichen sollen, operationelle Risiken mit statistischen Methoden zu quantifizieren. Mit Hilfe dieser Modelle soll das notwendige regulatorische und ökonomische Kapital bestimmt werden. Die beiden anderen Säulen beziehen sich auf den aufsichtlichen Überprüfungsprozess, in dem qualitative Anforderungen an Entwicklung und Dokumentation des Risikomanagements überprüft wird bzw. auf erweiterte Offenlegungspflichten, die den externen Druck auf das Risikomanagement der Banken erhöhen und somit zu mehr Marktdisziplin führen sollen. Die beiden letzten Säulen sind zwar auf qualitativer Ebene für die Banken von hoher Bedeutung; im Rahmen dieser Arbeit wird jedoch ausschließlich die quantitative erste Säule relevant sein.

Im Rahmen dieser Entwicklungen wächst dem Themenkomplex um die operationellen Risiken in der letzten Zeit in der Literatur zunehmendes Interesse zu. Während es in der Übersicht von Carol Alexander (Alexander 1996), bzw. (Alexander 1998a, b), in der umfassend über aktuelle Entwicklungen im Bereich der Risikosteuerung berichtet wird, noch keinerlei Erwähnung findet, sind in den letzten Jahren verschiedene Bücher und Schriften (Doerig 2000; Marshall 2000; King 2001; van den Brink 2002; Hoffman 2002;

Cruz 2002; Risk Books 2003; Alexander 2003a; Kaiser und Köhne 2004; Cruz 2004; Davis 2005) erschienen, die sich intensiv mit diesem Thema auseinandersetzen. Im wesentlichen Teilen beschäftigen sich diese Monographien mit den Grundlagen operationeller Risiken, der Definition, der Identifikation und dem Management. Es werden jedoch auch Modelle beschrieben, die zu einer Berechnung der durch operationelle Risiken entstehenden Risiken führen können. Dabei sind sowohl die Qualität als auch die Quantität der Daten Herausforderungen denen es sich zu stellen gilt.

Ziel dieser Arbeit ist eine Analyse der aus der Quantität der Daten resultierenden Probleme. Herausforderungen bezüglich der Datenqualität werden demgegenüber als gelöst vorausgesetzt. Dabei wird das in der Literatur am häufigsten verwendete Modell – das kollektive Modell der Versicherungen – zugrunde gelegt und es wird ermittelt, wie genau mit Hilfe dieses Modells operationelle Risiken quantifiziert werden können. Es werden Konfidenzintervalle bezüglich eines von der Aufsicht geforderten Niveaus von 99.9% zu unterschiedlichen Verteilungs- und Parameterannahmen berechnet und es wird gezeigt dass diese Intervalle in Abhängigkeit von den getroffenen Annahmen mehrere Größenordnungen umfassen können und den ursprünglichen Ergebnissen somit lediglich eine sehr beschränkte Aussagekraft zugestanden werden kann. Vielmehr müssen zusätzlich die Ergebnisse der hier gezeigten Berechnungen berücksichtigt werden, wodurch sich die Kapitalanforderungen deutlich erhöhen könnten.

Mit diesen Berechnungen soll der Sinn der Entwicklung quantitativer Modelle in keiner Weise in Frage gestellt werden. Es soll jedoch ein Bewusstsein dafür geschaffen werden, dass mit der zur Zeit verfügbaren Menge an Daten die Berechnungsergebnisse noch großen zufälligen Schwankungen unterliegen können, die bei der Ermittlung des notwendigen ökonomischen und regulatorischen Kapitals nicht vernachlässigt werden dürfen.

Im zweiten Kapitel wird die Behandlung operationeller Risiken im neuen Baseler Ka-

pitalakkord dargestellt. Dabei wird besonders auf die Daten eingegangen, die in den selbst zu entwickelnden Modellen Eingang finden sollen. Im dritten Kapitel wird ein typisches Verfahren vorgestellt, welches so als Basis für die Quantifizierung im Rahmen eines Verlustverteilungsansatzes verwendet werden kann. Dieses stammt aus der Versicherungslehre, in der die Quantifizierung ähnlicher Schäden bereits seit Jahren erfolgreich durchgeführt wird. Dabei werden die Schätzung einerseits mit Hilfe eines Maximum-Likelihood-Ansatzes durchgeführt; andererseits werden zusätzlich vorhandene Daten genutzt, um A-Priori-Aussagen über die zu schätzenden Parameter zu treffen. Diese werden dann mit Hilfe von Verfahren nach Bayes in den Schätzungen berücksichtigt. Die Beschreibung der Güte dieses Modells aufgrund der geringen Datenbasis im vierten Kapitel hängt thematisch eng mit dem dritten Kapitel zusammen. Aufgrund der Relevanz für diese Arbeit wurde dem Thema jedoch ein eigenes Kapitel gewidmet. Im fünften Kapitel wird dann ein selbst entwickeltes Verfahren vorgestellt, um die Genauigkeit der Schätzergebnisse zu bestimmen. Im sechsten Kapitel schließlich werden die zuvor erarbeiteten Verfahren simulationstechnisch umgesetzt und die Ergebnisse vorgestellt. Abschließende Schlussfolgerungen und mögliche zukünftige Forschungen finden sich dann in Kapitel sieben.

2. Operationelle Risiken in Basel II

Nach dem Inkrafttreten der überarbeiteten Rahmenvereinbarung zur internationalen Konvergenz der Kapitalmessung und Eigenkapitalanforderungen des Baseler Ausschusses für Bankenaufsicht¹ (im Folgenden **Basel II**) am 01.01.2007, der Annahme des Vorschlags für Richtlinien des Europäischen Parlaments und des Rates zur Neufassung der Richtlinie 2000/12/EG des Europäischen Parlaments und des Rates vom 20. März 2000 über die Aufnahme und Ausübung der Tätigkeit der Kreditinstitute und der Richtlinie 93/6/EWG des Rates vom 15. März 1993 über die angemessene Eigenkapitalausstattung von Wertpapierfirmen und Kreditinstituten (Kommission der Europäischen Gemeinschaften 2004) in den neuen Richtlinien 2006/48/EG bzw. 2006/49/EG am 14. Juni 2006 und der Veröffentlichung im Amtsblatt der Europäischen Union am 30. Juni 2006 (Europäisches Parlament und Rat 2006b, a) (im Folgenden **EU-Richtlinie**) und der nationalen Umsetzung der Regelungen von Basel II im Rahmen der neuen **Solvabilitätsverordnung** müssen deutsche Banken neben den Kredit- und Marktrisiken zusätzlich operationelle Risiken mit Eigenkapital unterlegen². Darüber hinaus werden sie ab diesem Zeitpunkt weitere Anforderungen an ihr Risikomanagement erfüllen müssen und können dadurch ggf. eine Verringerung dieser Unterlegung erreichen. Mit diesen

¹Basel Committee on Banking Supervision (2004)

²Für Banken in anderen EU-Ländern gelten diese Anforderungen nach der Umsetzung der EU-Richtlinie in das jeweilige nationale Recht; für Banken in Nicht-EU-Ländern nach der Umsetzung von Basel II in das jeweilige nationale Recht. Zusätzlich gelten für einige, international tätige Banken (die so genannten Basel Banken) die Anforderungen von Basel II auch direkt.

Anforderungen verfolgt das Baseler Komitee im Wesentlichen zwei Ziele (Anders 2001):

1. Operationelle Risiken sollen von den Banken angemessen gesteuert werden. Während bisher vielfach prozessuale Änderungen oder auch Outsourcing ausschließlich unter dem Gesichtspunkt möglicher Kosteneinsparungen betrachtet wurde, sollen somit auch eventuell erhöhte Risiken³, die durch die Verschlankung von Prozessen entstehen, in allen Kalkulationen berücksichtigt werden.
2. Banken sollen mögliche, große Verluste aus operationellen Risiken mit ihrem Eigenkapital auffangen können. Wenn Eigenkapital explizit für Verluste aus operationellen Risiken gehalten wird, kann dieses zum Tragen der Verluste eingesetzt werden. Eine mögliche Zahlungsunfähigkeit kann so abgewendet werden.

Da es bisher nicht gelungen ist, einen Standard für die Quantifizierung operationeller Risiken zu entwickeln, ist es den Banken gestattet, für die Berechnung eigene Methoden zu entwickeln, die dann von der jeweiligen nationalen Aufsicht anerkannt werden müssen.

Dabei wird den Banken eine bisher ungewohnte Flexibilität eingeräumt. Das Baseler Komitee erhofft sich dadurch eine Anreizwirkung, so dass Banken versuchen, eigene Quantifizierungsmodelle zu entwickeln und damit entscheidend zu der Etablierung eines Industriestandards beitragen werden⁴. Dabei wird der Aufsicht jedoch das Recht vorbehalten, alle verwendeten Ansätze intensiv zu prüfen und ggf. im Rahmen des aufsichtlichen Überprüfungsprozesses mit zusätzlichen Kapitalanforderungen zu versehen. So soll verhindert werden, dass Banken durch die Verwendung eines eigenen Modells ihr benötigtes Kapital beliebig klein rechnen.

³Wenn z.B. in Abteilungen Mitarbeiter abgebaut werden, um Redundanzen zur verringern, kann bei Ausfall des nun zum Know-How-Monopolisten gewordenen Mitarbeiters dessen Aufgabe nicht mehr erledigt werden, wodurch Verluste entstehen können.

⁴vgl. (Basel Committee on Banking Supervision 2004, Absatz 668)

In diesem Kapitel werden die wesentlichen Regelungen und Vorschläge des Baseler Komitees bezüglich des Managements und der Berechnung operationeller Risiken dargestellt. Im ersten Abschnitt wird die historische Entwicklung von Basel II erläutert und es wird dargestellt, warum Banken zu einer Mindesteigenkapitalquote verpflichtet werden. Anschließend wird die Definition operationeller Risiken vorgestellt und erläutert. Danach wird die Aufteilung der Bank und der Risikoereignisse in Business Lines einerseits und Risikokategorien andererseits dargestellt und erläutert. Schließlich werden zunächst die zur Quantifizierung verfügbaren Daten beschrieben und dann die unterschiedlichen aufsichtlich vorgegebenen Methoden zur Berechnung des notwendigen Kapitals dargestellt. Dabei sind nicht alle der dargestellten Daten in jeder Situation verfügbar (Reynolds und Syer 2002) und nicht alle werden in jedem Modell benutzt werden. Die Entscheidung, welche Daten wann benutzt werden, ist Teil des Risikomanagementprozesses. Vermutlich werden unterschiedliche Verfahren in unterschiedlichen Situationen anwendbar sein. Insbesondere ist es möglich, dass das regulatorische Kapital vom ökonomischen Kapital abweichen wird. Bisher erlaubt Basel Committee on Banking Supervision (2004) es der Bank, die Methoden selbst zu wählen, solange nicht ein einfacher Quantifizierungsansatz gewählt wird.

2.1. Entwicklung von Basel II

In Deutschland fordert das „Gesetz zur Kontrolle und Transparenz im Unternehmensbereich“ (KonTraG), dass der Vorstand geeignete Maßnahmen zu treffen und ein Überwachungssystem einzurichten hat, damit den Fortbestand der Gesellschaft gefährdende Entwicklungen rechtzeitig erkannt werden. Diese Regelung findet sich für Kreditinstitute zusätzlich im §25a Kreditwesengesetz (KWG). Hier werden die besonderen organisatorischen Pflichten von Kreditinstituten näher geregelt. Somit sind Banken auch heute

schon verpflichtet, operationelle Risiken zu identifizieren, zu messen und zu steuern.

Neben diesen gesetzlichen Grundlagen gibt es den Baseler Ausschuss für Bankenaufsicht (das Baseler Komitee), der aus Vertretern der Bankenaufsichten der großen Industrienationen besteht. Dieses Komitee unterbreitet Vorschläge, die häufig später direkten Einfluss auf die Gesetzgebung der Mitgliedsstaaten haben. Im Jahre 1992 veröffentlichte das Komitee die ursprüngliche Eigenkapitalvereinbarung (Basel I). Diese wurde später in vielen Fällen in nationale Gesetze übertragen und bildet heute u.a. die Grundlage für den Grundsatz I, welcher die Mindesteigenkapitalaussattung von Banken regelt. Im Rahmen einer grundlegenden Überarbeitung dieser Vereinbarung wurde 1999 das „Erste Konsultationspapier zur Neufassung der Eigenkapitalvereinbarung“ (Basel II) veröffentlicht, dem 2001 das zweite Konsultationspapier folgte (Fischer 2001). Nachdem im Februar 2003 die „Sound Practices“ (Basel Committee on Banking Supervision 2003c) und kurz darauf im Mai 2003 das dritte Konsultationspapier (Basel Committee on Banking Supervision 2003b, a) veröffentlicht wurden, wurde schließlich im September 2004 die neue Eigenkapitalvereinbarung (Basel Committee on Banking Supervision 2004) abschließend veröffentlicht.

In dieser wird neben den Adressausfall- und Marktpreisrisiken auch die vermeintlich neue Risikoart „operationelle Risiken“ als kapitalunterlegungspflichtig deklariert⁵. Infolgedessen werden operationellen Risiken sowie Möglichkeiten ihrer Berechnung erhöhte Aufmerksamkeit zuteil.

Die Eigenkapitalvereinbarung – kurz Basel II – soll zu einer risikosensitiven Berechnung des von Banken zu hinterlegenden Eigenkapitals führen. Die Vorschläge sollen

⁵Wie Stögbauer (2002) anmerkt, entspricht die aufsichtsrechtliche Verpflichtung zur Eigenkapital-Hinterlegung für OpRisk im Grunde einer impliziten Steuer, für die grundsätzlich drei Argumente angeführt werden können: Marktmacht, Existenz externer Effekte oder asymmetrische Information. Stögbauer (2002) zweifelt deren Existenz grundsätzlich an. In der Praxis werden diese Überlegungen nicht relevant sein, da die gesetzliche Anforderung zur Unterlegung von Risikokapital auch von den Vertretern der Bankenorganisationen nicht mehr angezweifelt wird.

von den jeweiligen nationalen Bankenaufsichten umgesetzt werden und Anfang 2007 in Kraft treten. Bei Ländern der EU gibt es zusätzlich die neue europäische Kapitaladäquanzrichtlinie (Europäisches Parlament und Rat 2006b, a). Diese ist kein Gesetz; die Mitgliedsstaaten der EU sind jedoch verpflichtet, die Richtlinie in Gesetze umzusetzen. Bei der nationalen Umsetzung kann somit noch auf die spezifischen nationalen Gegebenheiten eingegangen werden.

2.2. Definition und Abgrenzung

Operationelles Risiko ist „die Gefahr von Verlusten, die in Folge der Unangemessenheit oder des Versagens von internen Verfahren, Menschen und Systemen oder in Folge externer Ereignisse eintreten. Diese Definition schließt Rechtsrisiken⁶ ein, beinhaltet aber nicht strategische Risiken oder Reputationsrisiken“ (Basel Committee on Banking Supervision 2004).

Diese Definition des Komitees stellt voraussichtlich das Ende einer längeren Entwicklung dar. Zu ihrem Beginn wurde operationelles Risiko noch als Betriebsrisiko bezeichnet (Stocker u. a. 2001; Klomfass und Quandt 2001). Danach folgten unterschiedlichste Definitionsversuche. So wurde operationelles Risiko residual definiert als „jedes Risiko, das nicht Markt- oder Kreditrisiko ist“⁷ oder auch rekursiv als „any and all risks associated with operational issues“ (Dowd 1998, S. 191). Schließlich wurde OpRisk auch über Risikokategorien definiert als „a matter of defining the relevant types of events and adapting the experience of the insurance industry to operational risk“ (Reynolds und Syer 2002).

Die Definition des Komitees soll im Weiteren als Basis verwendet werden. Sie lässt

⁶Diese werden in Basel Committee on Banking Supervision (2004) nicht weiter definiert. Grundsätzlich wird darunter die Unsicherheit bzgl. der Durchsetzbarkeit von Verträgen verstanden (Dowd 1998, S. 199f).

⁷laut RMA u. a. (1999) verwendeten noch 1999 15% von 55 untersuchten Instituten diese Definition

jedoch noch einen weiten Raum für Interpretationen. Insbesondere der Begriff des Verlustes wird vorausgesetzt und nicht weiter definiert. Dabei stellt sich die Frage, wie mittelbar ein Verlust noch sein muss, um einem Risikoereignis zugeordnet werden zu können⁸. Weiterhin klärt diese Definition nicht vollständig die Abgrenzung zu anderen Risikoarten, insbesondere den ebenfalls mit Risikokapital zu unterlegenden Markt- und Kreditrisiken. Zwischen diesen auf der einen und operationellen Risiken auf der anderen Seite existieren zwei wesentliche Unterschiede:

1. *Erwerb, Aufgeben und Halten von Positionen*

Bei Markt- oder Kreditrisiken müssen Positionen zunächst explizit eingegangen werden. Bei operationellen Risiken entstehen die entsprechenden Positionen aus dem täglichen Geschäft heraus. Sie sind direkt mit dem entsprechenden Geschäft verbunden, werden nicht explizit gehalten und können daher auch nicht explizit aufgelöst werden, solange das entsprechende Geschäft abgewickelt werden soll. Es existiert daher kein in einem Anlagebuch oder einem Handelsbuch entsprechendes „OpRiskBuch“. Dagegen ist es – insbesondere bei Marktrisiken – relativ⁹ einfach, eine Position glatt zu stellen um das Risiko zu reduzieren. Zudem ist die Höhe eines Verlustes im Allgemeinen¹⁰ nach oben begrenzt und entspricht der Forderungshöhe bzw. dem Wert der Anlage, wohingegen Verluste aus operationellen Risiken zumindest theoretisch beliebig groß¹¹ werden können.

⁸Ist es z.B. noch operationelles Risiko, wenn ein Virus in das Computersystem der Bank eindringt, daraufhin aufgrund des Reputationsverlustes Umsatzverluste entstehen, die dazu führen, dass Personal abgebaut werden muss und dann ein entlassener Mitarbeiter eine Abfindung zugesprochen bekommt?

⁹solange ein Markt für das Wertpapier vorhanden ist

¹⁰abgesehen von einigen derivativen Produkten

¹¹In der betrieblichen Praxis muss zwischen Größen nicht mehr differenziert werden, wenn der Verlust so groß geworden ist, dass das Unternehmen diesen nicht übersteht.

2. *Endogenität des Risikos*

Bei Markt- oder Kreditrisiken ist das Risiko eines gegebenen Portfolios vom Unternehmen nicht zu beeinflussen. Die Einflussmöglichkeit beschränkt sich auf die Wahl desjenigen Portfolios, welches das gewünschte Risikoprofil beinhaltet. Auf das Risiko der Position selbst hat die Bank keinen Einfluss. In der aktuellen Forschung gibt es dazu auch teilweise gegenteilige Auffassungen¹², auf die im Weiteren jedoch nicht eingegangen werden soll. Selbst wenn es unterschiedliche Grade der Endogenität bzw. Exogenität geben sollte, ist unstrittig, dass bei operationellen Risiken die Endogenität mit weitem Abstand am stärksten ausgeprägt ist. Die Bank hat bei operationellen Risiken weiter gehende Einflussmöglichkeiten als bei Markt- oder Kreditrisiken. Während es schwierig, wenn nicht unmöglich ist, sich von bestimmten Positionen zu trennen¹³, können diese bei geeignetem Management auf die gewünschte Höhe gebracht werden. Dadurch jedoch fällt die Vorhersagekraft interner Verlustdaten. Wenn z.B. ein extrem großer Schaden durch einen Prozessfehler eingetreten ist, werden vermutlich die betroffenen Prozesse so modifiziert werden, dass ein solcher Verlust nicht erneut eintreten kann.

Neben den oben genannten Risiken sind für Banken auch noch Liquiditätsrisiken, strategische Risiken und Reputationsrisiken von Bedeutung. Die entsprechenden Abgrenzungen zu den anderen Risikoarten und die Berücksichtigung sind Herausforderungen, der sich die Banken in der Zukunft noch stellen müssen. Das Baseler Komitee gibt dabei in Basel II keinerlei Unterstützung, es wird lediglich in der Definition erwähnt, dass diese Risikoarten nicht Bestandteil des operationellen Risikos seien.

¹²z.B. Danielsson (2002)

¹³Die Risikoposition „Personen“ z.B. lässt sich nur abstoßen, wenn gleichzeitig das Unternehmen aufgelöst wird; ähnlich sieht dies bei den anderen Positionen auf. Nur teilweise lassen sich Risiken durch Versicherungen transferieren; ebenso entstehen so neue operationelle Risiken, z.B. bei der Ausgestaltung der Versicherungsbedingungen.

2.3. Risikokategorien und Business Lines

Sofern eine Bank plant, einen ambitionierten Messansatz (vgl. Abschnitt 2.6.3) einzusetzen und somit eigene Quantifizierungsmodelle entwickelt, muss das von ihr verwendete Messsystem ausreichend granular und detailliert sein (Basel Committee on Banking Supervision 2004, Absatz 669). Diese Anforderung bezieht sich auf die beiden Dimensionen „Risikokategorie“, in der die Ereignisse nach ihren Haupttreibern klassifiziert werden müssen und „Geschäftsfelder“, in die die Aktivitäten der Bank aufgeteilt werden sollen.

2.3.1. Business Lines nach Basel II

Eine Business Line – auch als Geschäftsfeld bezeichnet – ist eine Menge von zusammenhängenden Einheiten, der (logisch oder physikalisch) operationelles Risiko zugeordnet werden kann (Reynolds und Syer 2002). Das Baseler Komitee schlägt vor, die Aktivitäten der Bank in die acht Felder

- Unternehmensfinanzierung/-beratung
- Handel
- Privatkundengeschäft
- Firmenkundengeschäft
- Zahlungsverkehr und Wertpapierabwicklung
- Depot- und Treuhandgeschäfte
- Vermögensverwaltung
- Wertpapierprovisionsgeschäft

aufzuteilen. Eine detailliertere Darstellung nach Basel Committee on Banking Supervision (2004) findet sich in Tabelle 2.1. Dieser Vorschlag muss von der Bank nicht unter allen Umständen vollständig übernommen werden, lediglich eine Abbildung aller Tätigkeiten der Bank auf eines dieser Geschäftsfelder muss vorgenommen werden können. Sowohl dabei, wie auch bei der Verwendung einer eigenen Aufteilung ist darauf zu achten, dass sich Geschäftsfelder nicht wechselseitig überschneiden und alle zusammen das Unternehmen vollständig darstellen.

Ebene 1	Ebene 2	Aktivitäten
Unternehmensfinanzierung -beratung (Corporate Finance)	Unternehmensfinanzierung/ -beratung	Unternehmenszusammenschlüsse, Emissions- und Platzierungsgeschäft, Privatisierung, Verbriefung, Research, Kredite (Regierungen, High Yield), Beteiligungen, Syndizierungen, Börsengang, Privatplatzierungen, weitere Unternehmensberatungsdienstleistungen
	öffentliche Haushalte	
	Handelsfinanzierungen	
	Beratungsgeschäft	
Handel (Trading & Sales)	Kundengeschäfte	Anleihen, Aktien, Devisengeschäfte, Warenhandel, Derivate, Mittelanlage, Mittelaufnahme, Eigenhandel, Wertpapierleihe und Repos, Brokerage (Orderausführung und Service für professionelle Investoren), prime brokerage
	Market Making	
	Eigenhandel	
	Treasury	
Privatkundengeschäft (Retail Banking)	Massengeschäft	Für Privatkunden: Einlagen- und Kreditgeschäft (ggf. auch Immobilien), Serviceleistungen, Treuhändergeschäft, Anlageberatung
	Private Banking	Für Vermögendere: private Finanzierungen und Geldanlagen, Serviceleistungen, Treuhändergeschäft, Vermögens- und Anlageberatung
	Kartenservices	Handels-/Gewerbe-/Unternehmenskarten, individuelle Karten und Massengeschäft
Firmenkundengeschäft (Commercial Banking)	Firmenkundengeschäft	Projektfinanzierung, Immobilienfinanzierung, Exportfinanzierung, Handelsfinanzierung, Factoring, Leasing, Kreditgewährungen, Bürgschaften und Garantien, Wechselgeschäft für Firmenkunden
Zahlungsverkehr und Abwicklung (Payment & Settlement)	Externe Kunden, Dritte	Zahlungsverkehr, Geldtransfersgeschäft, Clearing und Wertpapierabwicklung für Dritte
Depot- und Treuhandgeschäfte (Agency Services)	Depot, Verwahrung	Treuhandverwahrung, Depotgeschäft, Custody, Wertpapierleihe (für Kunden); weiterer Service für Unternehmen
	Treuhandgeschäft	Emissions- und Zahlstellenfunktionen
	Stiftungen	
Vermögensverwaltung (Asset Management)	gebundene Vermögensverwaltung	Pool-, einzeln, privat, institutionell, geschlossen, offen, „Private Equity“
	freie Vermögensverwaltung	Pool, einzeln, privat, institutionell, geschlossen, offen
Wertpapierprovisionsgeschäft (Retail Brokerage)	Ausführung von Wertpapieraufträgen	Ausführung von Orders, Verwaltungsgeschäft für Privatkunden

Tabelle 2.1.: Zuordnung der Business Lines nach Basel II

2.3.2. Risikokategorien nach Basel II

Bei der Kategorisierung von Risiken die zu Verlusten aus operationellen Risiken führen, kann grundsätzlich zwischen einem ereignisbasierten und einem ursachenbasierten Ansatz unterschieden werden. Bei dem Erstgenannten werden die verschiedenen Ereignisse, wie z.B. ein Stromausfall oder ein Betrug, die zu Verlusten führen können, Ereigniskategorien zugeordnet und somit zur Klassifizierung verwendet. Dabei werden die entsprechenden Ursachen nicht weiter untersucht. Diese Ursachen werden dann beim ursachenbasierten Ansatz für die Abgrenzung verwendet. Diese Abgrenzung ist nicht immer trivial, da Ereignisse auch Ursache für weitere Ereignisse sein können. Daher muss sich im Laufe der Zeit erst noch ein Konsens darüber entwickeln, welche Kategorisierung für das Management operationeller Risiken optimal ist.

Ziel der Aufsicht war es ursprünglich, nach Ereignissen zu kategorisieren¹⁴. Die aktuelle Kategorisierung aus dem Akkord ist in Tabelle 2.2 dargestellt. Diese entspricht jedoch einer Mischung beider möglichen Ansätze (Samad-Kahn 2002). Daher schlägt Samad-Kahn (2002) ein neues System von Kategorien vor; auch viele Banken haben für ihre Risikosteuerung eigene Kategorien entwickelt. Nach dem neuen Baseler Akkord ist die Verwendung eines anderen Systems zulässig, solange die Zuordnung eines Verlustes zu den Baseler Kategorien zumindest auf der ersten Ebene möglich ist.

Die Verknüpfung von Ereignissen und entsprechenden Schäden kann mehr oder weniger direkt sein. In Wurm (2001) werden drei verschiedene Klassen von Verknüpfungen genannt:

- *Direkte Verbindungen*

Eintritt und Schaden sind klar feststellbar. Dies gilt z.B. für internen Betrug oder

¹⁴Der Akkord spricht daher regelmäßig von Verlustereignissen und Risikoereignissen, nicht aber von Ursachen

auch den unautorisierten Wertpapierhandel. Diese Risiken werden deshalb im Rahmen der Risikomessung auch als „harte Risiken“ bezeichnet.

- *Gemischte Verbindungen*

In der Regel ist der Eintritt klar feststellbar, der Schaden aber nur indirekt berechenbar. Dies betrifft z.B. Krankheit, Streik oder Kündigung.

- *Indirekte Verbindungen*

Hierbei können die Risikoarten weder hinsichtlich der Eintrittswahrscheinlichkeit noch hinsichtlich des Schadens isoliert werden. Dies trifft z.B. für die Bereiche Motivation, inadäquate Führung etc. zu. Hier ist es auch nicht möglich, über das Rating von personalspezifischen Teilen des internen Kontroll- und Überwachungssystems messungsrelevanten Input zu bekommen. In diesem Zusammenhang spricht man deshalb auch von so genannten „weichen Risiken“.

Insbesondere bei den weichen Risiken ist es häufig eine anspruchsvolle Aufgabe, Ereignissen entsprechende Kategorien zuzuordnen. Als Hilfestellung wird in ORX Association (2004) vorgeschlagen, für eine angemessene Kategorisierung auf die Frage nach dem Warum zu verzichten, sondern danach zu fragen, was das entsprechende Ereignis verursacht hat, wobei darauf zu achten sei, dass die Antwort in das vorgegebene Schema passt.

Ereigniskategorie (1. Ebene)	Definition	Ereigniskategorie (2. Ebene)	Beispiele (3. Ebene)
Interner Betrug	Verluste aufgrund von Handlungen mit betrügerischer Absicht, Veruntreuung von Eigentum, Umgehung von Vorschriften, Gesetzen oder internen Bestimmungen; ausgenommen sind Ereignisse, die auf Diskriminierung oder (sozialer und kultureller) Verschiedenheit beruhen und an denen mindestens eine interne Partei beteiligt ist	Unbefugte Handlungen	Nicht geneigte Transaktionen (vorsätzlich) Unzulässige Transaktionen (mit finanziellem Verlust) Ausnutzung der eigenen Position (vorsätzlich)
		Diebstahl und Betrug	Betrug / Kreditbetrug / Einlagen ohne Wert Diebstahl / Erpressung / Veruntreuung / Raub Veruntreuung von Vermögenswerten Böswillige Vernichtung von Vermögenswerten Fälschung Scheckbetrug Schmuggel Kontofolternahme / Identitätsfälschung / usw. Steuerdelikt / Steuerhinterziehung (vorsätzlich) Bestechung / Schmiergeldzahlung Insidergeschäft (nicht auf Rechnung des Arbeitgebers)
Externer Betrug	Verluste aufgrund von Handlungen mit betrügerischer Absicht, Veruntreuung von Eigentum oder der Umgehung des Gesetzes durch einen Dritten	Diebstahl und Betrug	Diebstahl / Raub Fälschung Scheckbetrug
		Systemicherheit	Schäden durch Hackeraktivitäten Diebstahl von Informationen (mit finanziellem Schaden) Ausgleichszahlungen, Zuwendungen, Abfindungen Gewerkschaftsaktivitäten
Beschäftigungspraxis und Arbeitsplatzsicherheit	Verluste aufgrund von Handlungen, die gegen Beschäftigungs-, Gesundheits- oder Sicherheitsvorschriften bzw. -abkommen verstößen; Verluste aufgrund von Zahlungen aus Ansprüchen wegen Körperverletzung; Verluste aufgrund von Diskriminierung bzw. sozialer und kultureller Verschiedenheit;	Ereignisse in Verbindung mit Arbeitnehmern	Allgemeine Haftpflicht (Ausrutschen und Stürzen, usw.) Verstoß gegen Gesundheits- und Sicherheitsbestimmungen Kompensations-/Schadensersatzzahlungen an Arbeitnehmer
		Sicherheit des Arbeitsumfeldes	jede Art von Diskriminierung Verstoß gegen treuhänderische Pflichten / Verletzung von Richtlinien Angelegenheiten in Bezug auf Angemessenheit und Offenlegung („Know your customer“-Regelungen) Verletzung von Informationspflichten gegenüber Verbraucher/Privatkunden Verletzung der Privatsphäre, des Datenschutzes aggressive Verkaufspraktiken Provisionschneiderei Missbrauch vertraulicher Informationen Haftung des Darlehensgebers
Kunden, Produkte & Geschäftsgepflogenheiten	Verluste aufgrund einer unbeabsichtigten oder fahrlässigen Nichterfüllung geschäftlicher Verpflichtungen gegenüber bestimmten Kunden (einschließlich treuhänderischer und auf Angemessenheit beruhender Verpflichtungen); Verluste aufgrund der Art oder Struktur eines Produktes	soziale und kulturelle Verschiedenheit/Diskriminierung	Antitrust (Kartell) unzulässige Geschäfts-/Marktpraktiken Marktmanipulationen Insidergeschäfte (auf Rechnung des Arbeitgebers) unkonzessionierte Geschäftstätigkeit Geldwäsche Produktmangel (unbefugt, usw.) Modellfehler
		Unzulässige Geschäfts- oder Marktpraktiken	Versagen bei der Kundenprüfung mittels Richtlinien

Tabelle 2.2.: Risikokategorien – Detaillierte Klassifikation nach Basel II

Ereigniskategorie (1. Ebene)	Definition	Ereigniskategorie (2. Ebene)		Beispiele (3. Ebene)	
		Kreditausfall	Beratungstätigkeiten	Überschreitung des Kundengesamtlimits	Anpassungen über Performance/Ergebnis der
Sachschäden	Verluste aufgrund von Beschädigungen oder des Verlustes von Sachvermögen durch Naturkatastrophen oder andere Ereignisse		Katastrophen und andere Ereignisse	Wahrnehmung von Beratungstätigkeiten	
Geschäftsunterbrechungen und Systemausfälle	Verluste aufgrund von Geschäftsunterbrechungen oder Systemausfällen			Verluste durch Naturkatastrophen	Personenschäden aufgrund von externen Ereignissen (Terrorismus, Vandalismus)
Abwicklung, Vertrieb und Prozessmanagement	Verluste aufgrund von Fehlern bei der Geschäftsabwicklung oder im Prozessmanagement; Verluste aus Beziehungen mit Geschäftspartnern und Lieferanten/Anbietern		Systeme	Hardware	Software
				Telekommunikation	Versorgungsausfall/-störung
			Erfassung, Abwicklung & Betreuung von Transaktionen	Kommunikationsstörungen	Fehler bei der Dateneingabe, -pflege oder -speicherung
				Überschreiten eines Termins oder Nichterfüllung einer Aufgabe	Fehlerhafte Anwendung von Modellen/Systemen
				Buchführungsfehler / falsche Prozesszuordnung	Fehler bei der Durchführung sonstiger Aufgaben
				Fehlerhafte Lieferung	Fehlerhafte Verwaltung von Versicherungsinstrumenten
				Pflege der Referenzdaten	Nichteinhaltung der vorgeschriebenen Meldepflicht
			Überwachung und Meldung	Ungenauer externer Bericht (Schaden eingetreten)	Freigabe durch Kunden/ Haftungsausschluss fehlt
			Kundenaufnahme und -dokumentation	Rechtsdokumente fehlen/unvollständig	Ungenehmigter Zugriff auf Konten
			Kundenkontoführung	Fehlerhafte Kundenunterlagen (Schaden eingetreten)	Fahrlässiger Verlust/Beschädigung von Kundenvermögenswerten
			Geschäftspartner	Fehlerhafte Erfüllung durch Geschäftspartner (Nichtkunden)	Verschiedene Unstimmigkeiten mit Geschäftspartnern (Nichtkunden)
			Lieferanten und Anbieter	Outsourcing	Unstimmigkeiten mit Lieferanten

Tabelle 2.2: Risikokategorien – Detaillierte Klassifikation nach Basel II (Fortsetzung)

2.3.3. Berücksichtigung von Abhängigkeiten

Aus der Kombination der acht Risikokategorien und der sieben Unternehmenseinheiten ergibt sich eine Matrix mit 56 Feldern, für die das operationelle Risiko jeweils separat zu berechnen ist. Die operationellen Risiken für die Gesamtbank ergeben sich nach der Quantifizierung der einzelnen Matrixfelder aus der einfachen Addition der isoliert voneinander berechneten Zellenwerte, solange die Bank nicht andere Abhängigkeiten nachweisen kann (Basel Committee on Banking Supervision 2004).

Diese durch die Vorgabe der Addition unterstellte vollständig positive Korrelation zwischen den einzelnen Zellen ist sicherlich als sehr konservativ zu betrachten. Sinnvoller wäre es, wenn man den Banken im Rahmen ihrer Modellentwicklung erlauben würde, Korrelationsfaktoren mit in die Modellierung einfließen zu lassen. Auch sollte es den Banken offen stehen, direkt die Gesamtverteilungsfunktion für operationelle Risiken zu verwenden und damit Korrelationen zwischen den Risikoarten implizit und empirisch zu berücksichtigen. (Mathmann 2003)

2.4. Quantitative Informationsquellen

Damit die Höhe des operationellen Risikos ermittelt werden kann, müssen geeignete Daten erhoben werden, die einen Aufschluss über die aktuelle und die zukünftige Risikosituation der Bank geben. In diesem Abschnitt werden die in Basel Committee on Banking Supervision (2004) erwähnten möglichen Datenquellen vorgestellt.

Dabei wird zwischen quantitativen und qualitativen Datenquellen unterschieden. Bei quantitativen Quellen lassen sich direkt aus den Daten Aussagen über die Häufigkeit oder die Höhe zu erwartender Verluste ableiten. Im Gegensatz dazu ist dies bei qualitativen Quellen nicht möglich. Bei diesen sind die Ergebnisse z.B. Ratings, für die – ähnlich wie

bei Ratings für Kredite – vermutet wird, dass es einen Zusammenhang zwischen Rating und zukünftigen Verlusten aus operationellen Risiken gibt. Weiterhin existieren noch qualitative Quellen, bei denen die Einschätzungen ohne Ratings in Textform vorliegen. Die qualitativen Quellen werden in Abschnitt 2.5 beschrieben, im Rahmen der Modelle jedoch nicht weiter berücksichtigt.

2.4.1. Interne Verlustdaten

Interne Verlustdaten sind Informationen über Verluste aufgrund von operationellen Risiken, die im eigenen Unternehmen¹⁵ aufgetreten sind. Diese stellen die Basis und die wichtigste Quelle für eine Quantifizierung dar. In Embrechts u. a. (2002) werden typische Eigenschaften operationeller Verlustdaten beschrieben. Sie lassen sich insbesondere in einen großen Anteil kleiner Verluste und einen sehr kleinen Anteil sehr großer Verluste aufteilen. Dabei ist die absolute Zahl der in den Datenbanken vorhandener Verlustdaten insgesamt bislang sehr gering¹⁶. Weiterhin sind sie irregulär über die Zeitachse verteilt, wobei die Tendenz besteht, dass ihre Anzahl mit der Zeit zunimmt. Diese mag jedoch auch auf einer Veränderung der internen Prozesse zur Messung beruhen, durch den im Laufe der Zeit mehr Verluste berichtet werden.

Das Sammeln interner Verlustdaten ist regulatorische Anforderung und wesentlicher Bestandteil des Managements operationeller Risiken. Aufgrund ihres quantitativen Charakters bieten sich interne Verlustdaten als Ausgangspunkt für eine Quantifizierung an, wenn die folgenden Informationen über jedes Verlustereignis vorliegen:

¹⁵Die Problematik der Abgrenzung des eigenen Unternehmens wird im Rahmen dieser Arbeit nicht behandelt.

¹⁶Genaue Zahlen sind nicht bekannt, da Banken grundsätzlich keinerlei Angaben über ihre internen Verlustdatenbanken veröffentlichen.

- Bruttoverlust

Der Bruttoverlust ist die absolute Höhe des eingetretenen Verlustes vor Abzug jeglicher Verlustminderungen wie z.B. Versicherungen. Bei der praktischen Bestimmung kann bei Totalverlust oder der Beschädigung von materiellen Gütern unterschieden werden zwischen dem Anschaffungswert, dem Buchwert und dem Wiederbeschaffungswert. Insbesondere bei immateriellen Gütern aber auch bei z.B. Kunst kann die Bestimmung des Bruttoverlustes eine große Herausforderung sein.

Es ist möglich, dass zu einem Verlustereignis mehrere Schäden auftreten. Dies muss ebenfalls angemessen berücksichtigt werden. Schließlich können zu einem Risikoereignis nicht nur Verluste auftreten, sondern auch Gewinne¹⁷ erzielt werden, die dann ebenfalls in der Quantifizierung berücksichtigt werden müssten. Vermutlich wird in der Praxis die Sammlung entsprechender Informationen nicht durchführbar sein.

Damit die Verlustdatensammlung durchführbar wird, muss ein Schwellenwert spezifiziert werden, der angibt, ab welchem Betrag Verlustdaten gesammelt werden sollen. Dieser kann in verschiedenen Unternehmensbereichen oder für unterschiedliche Risikokategorien auch unterschiedliche Höhen haben. Im Basel Committee on Banking Supervision (2004) wird ein Schwellenwert von 10.000 Euro erwähnt, der auch in den Modellen in Kapitel 6 verwendet wird.

- Datum

Welches das zu einem Verlust gehörende Datum ist, wird zur Zeit von vielen Banken diskutiert. Dabei können unterschiedliche Zeitpunkte relevant sein: das Datum des Auftretens des Ereignisses oder des Verlustes, das Datum der Erkennung des

¹⁷z.B. kann es sein, dass ein Händler ein falsches Wertpapier kauft, dadurch jedoch ein höherer Ertrag erzielt wird, als durch als Wertpapier, das der Händler ursprünglich kaufen wollte.

Ereignisses oder des Verlustes, das Datum, an dem der Verlust reguliert wurde und das Datum seiner endgültigen Verbuchung. Diese Daten können alle verschieden sein, teilweise können sie auch keine Zeitpunkte, sondern sogar Zeiträume sein. Teilweise sind sie nicht einmal existent, so z.B. wenn ein Schaden nicht verbucht worden ist, oder sie treten mehrfach auf, wenn zu einem Ereignis mehrere Verluste aufgetreten sind oder diese Verluste in mehreren Raten ausgeglichen wurden.

Für die Quantifizierung ist zu beachten, dass nach dem Auftreten des Ereignisses ein beliebig langer Zeitraum bis zur endgültigen Verbuchung verstreichen kann; teilweise wird erst ein Teil des Schadens entdeckt und erst durch eine detaillierte Untersuchung kann das gesamte Ausmaß erkannt werden. Es wird daher im Vorhinein nicht bekannt sein, wie lange es dauert, bis alle Untersuchungen abgeschlossen sind, und keine weiteren zugehörigen Verluste mehr bekannt werden. Dadurch können je nach Auswahl des relevanten Datums systematische Verschiebungen in der Datensammlung auftreten.

- Basel II Geschäftsfeld¹⁸ des risikotragenden Bereichs

Für Verlustereignisse können bis zu drei unterschiedliche Geschäftsfelder relevant sein. Das Geschäftsfeld, in dem das Ereignis auftritt, das Geschäftsfeld, das das Ereignis verursacht hat und dasjenige, das aufgetretene Schäden schließlich bezahlen muss, das risikotragende Geschäftsfeld. Für die Quantifizierung ist lediglich das letztgenannte relevant; für die Steuerung und das Management operationeller Risiken werden häufig auch die anderen beiden erhoben.

Nicht immer müssen drei unterschiedliche Geschäftsfelder betroffen sein, jedoch kann es in vielen Fällen auch vorkommen, dass Ereignissen die entsprechenden Bereiche nicht immer eindeutig zuzuordnen sind. Insbesondere Naturkatastrophen

¹⁸vgl. Tabelle 2.1 auf Seite 15

betreffen in vielen Fällen nicht einzelne, sondern mehrere Geschäftsfelder, in einigen Fällen kann auch die gesamte Bank betroffen sein.

- Basel II Risikokategorie 1. Ebene¹⁹

Jedem Verlustereignis muss eine Risikokategorie zugeordnet werden. Wenn die Kategorien überschneidungsfrei und vollständig aufgestellt wurden, ist eine eindeutige Zuordnung möglich.

Bei tatsächlich gesammelten Daten von Verlustereignissen sind häufig noch mehr Informationen wie z.B. eine detaillierte Beschreibung des Ereignisses²⁰ oder Buchungsinformationen enthalten. Für die tatsächliche Durchführung der Datenerhebung wird wohl in den meisten Fällen eine softwaregestützte Lösung eingeführt werden. Eine solche ist z.B. in Höfer und Schrott (2003) beschrieben.

Eine große Herausforderung an die mit der Sammlung der Daten betrauten Personen ist die Reduktion der vermuteten hohen Dunkelziffer von Verlusten. Da die explizite Beschäftigung mit operationellen Risiken noch relativ neu ist, ist es vielen Mitarbeitern im Unternehmen nicht bewusst, dass Schäden aus operationellen Risiken gemeldet und in Datenbanken gesammelt werden müssen, um eine Quantifizierung zu ermöglichen. Weiterhin ist bei dieser Risikoart immer zumindest mittelbar eine Person, häufig ein Mitarbeiter des Unternehmens selbst, für das Eintreten des Verlustes verantwortlich. Da eigene Fehler ungern zugegeben werden²¹, besteht für die betroffenen Mitarbeiter die Tendenz den Verlust zu verschweigen. In vielen Fällen kann eine Erkennung dennoch

¹⁹vgl. Tabelle 2.2 auf Seite 18

²⁰Diese kann dann ähnlich wie die Beschreibungen externer Verlustereignisse auch für die Erstellung von Szenarien (vgl. Abschnitt 2.5.3) verwendet werden.

²¹Diese Einstellung könnte jedoch prinzipiell durch eine verbesserte Risikokultur geändert werden. Den Mitarbeitern muss vom Unternehmen das Bewusstsein vermittelt werden, dass jeder Fehler machen darf und niemandem damit geholfen ist, wenn Fehler verschwiegen werden. Dennoch wird die Umsetzung einer erfolgreichen Strategie zur Verbesserung der Risikokultur eine der schwierigsten Aufgaben innerhalb der Behandlung operationeller Risiken sein.

möglich sein. Wenn z.B. Sonderabschreibungen vorgenommen werden, wird dies bei einer genauen Prüfung aller Buchungen auffallen²²; wenn jedoch ein Händler eine falsche Anzahl Wertpapiere kauft und er sich entscheidet, entgegen seiner ursprünglichen Absicht, diese Papiere zu halten, kann nicht festgestellt werden, dass dies ein Verlust aus operationellen Risiken war.

Schließlich sollen mit der Quantifizierung operationeller Risiken sehr hohe Quantile wie z.B. ein 99,9%-Quantil über ein Jahr bestimmt werden (Basel Committee on Banking Supervision 2004). Ein Jahresverlust, der mindestens diesem Quantil entspricht wird im Mittel alle 1.000 Jahre auftreten. Unternehmen jedoch verändern sich im Laufe der Zeit, um sich an neue Rahmenbedingungen anzupassen. Dadurch ändern sich die Prozesse innerhalb des Instituts; Risiken verschwinden, andere kommen neu hinzu. Möglicherweise sind nach der vollständigen Abwicklung eines Verlustes inklusive aller notwendigen Untersuchungen, die Prozesse, die zu diesem geführt haben, vollständig modifiziert worden, so dass die Aussagekraft bezüglich des Eintretens weiterer, ähnlicher Verluste nahezu nicht mehr vorhanden ist. Aus diesem Gründen sollten Verluste nach einigen Jahren nicht mehr direkt für die Quantifizierung verwendet werden. Daher werden in der internen Datenbank nur wenige bzw. keine Verluste entsprechender Höhe enthalten sein. Selbst wenn die Verlustverteilung richtig geschätzt werden kann, wird dies lediglich für den Bereich der Verteilung gelten, für den auch Daten vorhanden sind, nicht aber für die in diesem Fall wichtigen Ränder der Verteilung, da es fraglich ist, ob alle Daten innerhalb einer Kategorie tatsächlich vom gleichen verlustgenerierenden Prozess oder der gleichen Verteilung stammen. Für die Schätzung von Extremereignissen werden daher vermutlich niemals genügend relevante interne Verlustdaten zur Verfügung stehen.

²²Ein prinzipiell denkbares Vorgehen; in der Praxis wird dies jedoch an dem enormen Aufwand scheitern, den eine eingehende Prüfung aller Buchungen der Bank mit sich bringen würde.

Daher werden Banken hochfrequente Ereignisse angemessen behandeln (Buchmüller 2002, 2001) können, bei den niederfrequenten Ereignissen, kann es jedoch zu systematischen Verschiebungen und zu einer Fehlberechnung des Kapitals kommen.

2.4.2. Externe Verlustdaten aus öffentlichen Quellen

Externe Verlustdaten aus öffentlichen Quellen sind Verluste aus operationellen Risiken, über die öffentlich berichtet wurde und die nicht in dem Unternehmen, auf das das Modell angewendet werden soll²³, aufgetreten sind.

Externe Verlustdaten können zwei Zielen dienen. Zum Einen können sie für die Erstellung von Szenarien verwendet werden. Dabei wird von der Annahme ausgegangen, dass in anderen Unternehmen ähnliche Verlustereignisse auftreten können und man durch die Analyse fremder Schadensfälle aus den Fehlern anderer Unternehmen lernen kann.

Zum Anderen können sie – ähnlich wie die internen Verlustdaten – für die Schätzung von Verlustverteilungen verwendet werden. Dieser Umstand erscheint zunächst widersprüchlich, denn wie sollen die Verluste anderer Unternehmen Aufschluss über die Risikosituation des eigenen Instituts geben? Die Auffassung, die dieser Art der Nutzung zugrunde liegt ist die, dass ähnliche Unternehmen auch ähnlichen Risiken ausgesetzt sind und dass damit auch eine ähnliche Verteilungsfunktion mit ähnlichen Parametern unterstellt werden kann. Ggf. müssen diese Parameter noch auf die Größe des eigenen Instituts skaliert werden. Wenn diese Annahme grundsätzlich akzeptiert wird und geeignete Skalierungen durchgeführt wurden, stellen sie eine sinnvolle Möglichkeit dar, Informationen über Extremereignisse zu sammeln. Allerdings wird in öffentlichen Quellen nicht systematisch berichtet, sondern lediglich über Ereignisse, die für einen Autor zunächst bekannt geworden sind und ihm zusätzlich interessant genug für eine Veröffentlichung

²³vgl. Fußnote 15 auf Seite 21

erscheinen. Daher kommen sie für eine Häufigkeitsschätzung nicht in Betracht. Für eine Höhenschätzung stellen sie eine gute Möglichkeit dar, wenn gewährleistet oder mindestens plausibilisiert werden kann, dass die erhaltenen Daten für das eigene Unternehmen relevant sind und der Struktur nach im eigenen Unternehmen ebenfalls auftreten könnten. Dabei muss jedoch berücksichtigt werden, dass über Verluste tendenziell häufiger berichtet wird, je größer sie sind. Dies kann prinzipiell bei der Entwicklung von Modellen berücksichtigt werden (de Fontnouvelle u. a. 2003a).

Diese Tatsache, dass über größere, bekannt gewordene Verluste aus operationellen Risiken in den Medien berichtet wird, haben sich einige Unternehmen²⁴ zu Nutze gemacht und bieten Banken solche Daten gegen Entgelt an.

Es werden grundsätzlich dieselben Informationen wie bei den internen Verlustdaten benötigt. In diesem Fall hat die Bank jedoch keinen Einfluss auf Begriffsdefinitionen, Qualitätsstandards und den Erhebungsprozess. Zusätzliches Hindernis wird es sein, dass andere Unternehmen häufig versuchen werden, Informationen über eingetretene Verluste aus operationellen Risiken möglichst nicht zu veröffentlichen, um einen drohenden Reputationsverlust zu vermeiden. Ebenso werden lediglich solche Verluste in der Presse erscheinen, die von dieser für eine Veröffentlichung interessant genug gehalten werden. Dadurch wird eine systematische Erhebung erschwert.

Schließlich ist die Frage relevant, in wie weit sich Verluste anderer Unternehmen sowohl in der Sache als auch in der Höhe auf das eigene Institut übertragen lassen. Für die Anwendbarkeit müssen geeignete Kriterien für die Ähnlichkeit²⁵ gefunden werden, deren Erstellung nicht diskutiert werden soll. Verlusthöhen müssen eventuell auf die Größe des eigenen Unternehmens skaliert werden (de Fontnouvelle u. a. 2003b, a, 2004). In dieser

²⁴z.B. FitchRiskManagement mit der OpVantageFirst Datenbank, SAS mit den Daten von OpRisk-Analytics oder Aon, ein Versicherungsmakler, der zusätzlich noch anonymisierte Daten zu ihm bekannt gewordenen Versicherungsfällen anbietet

²⁵z.B. Bilanzkennzahlen, Branchenzugehörigkeit

Richtung wurde bereits einige Forschung betrieben, die Daten aus öffentlichen Quellen verwendet hat (Baud u. a. 2002; Frachot und Roncalli 2002; Roehr 2002). Da Unternehmen ihre internen Verlustdaten jedoch streng vertraulich behandeln, sind keine weiteren Daten für Forschungszwecke verfügbar. Eventuell ergeben sich solche Forschungsmöglichkeiten durch die Datenkonsortien²⁶. Immerhin finden de Fontnouvelle u. a. (2004) heraus, dass Daten aus externen Quellen ein überraschendes Maß an statistischer Übereinstimmung zeigen. Sie folgern, dass die Details und die Chronologie dieser Verlustereignisse ideosynkratisch sind und eine Modellierung mit Hilfe von Daten unterschiedlicher Unternehmen daher Sinn macht.

2.4.3. Externe Verlustdaten aus Datenkonsortien

Externe Verlustdaten aus Datenkonsortien sind Verluste aus operationellen Risiken, die nicht in dem Unternehmen, auf das das Modell angewendet werden soll²⁷, aufgetreten sind und die dem eigenen Unternehmen im Rahmen der Teilnahme an einem Datenkonsortium bekannt geworden sind.

Um der regulatorischen Anforderung der Nutzung von externen Verlustdaten im Rahmen der ambitionierten Messansätze gerecht zu werden, haben sich einige Kreditinstitute zu Konsortien zusammengeschlossen mit dem Zweck Verlustdaten untereinander auszutauschen. Das bekannteste dieser Konsortien ist ORX (Operational Risk Data Exchange), ein in der Schweiz ansässiger Verein weltweit führender Banken; weitere sind GOLD und für den deutschsprachigen Raum das Konsortium des Verbands öffentlicher Banken (VÖB), welches z.Zt. im Aufbau begriffen ist.

Diese Daten sind ihrem Wesen nach den Verlustdaten aus öffentlichen Quellen recht ähnlich und können daher gleichen Zwecken dienen wie diese. Neben der Nutzung für die

²⁶vgl. Kapitel 2.4.3

²⁷vgl. Fußnote 15 auf Seite 21

Erstellung von Szenarien, werden sie vorrangig für die Plausibilisierung von Verteilungsannahmen und die Schätzung entsprechender Parameter sowie für ein Benchmarking der eigenen Verluste verwendet werden (Hoffman 2000/2001), da die Daten aus internen Quellen stammen und damit glaubwürdiger und zuverlässiger sind als Daten, die der Öffentlichkeit bekannt geworden sind. Dadurch kann die verfügbare Datenbasis bei gleichzeitiger Wahrung der Vertraulichkeit sichergestellt werden. Aufgrund der systematischen Sammlung können sie im Gegensatz zu öffentlich verfügbaren Daten zusätzlich für eine Häufigkeitsschätzung verwendet werden. Es ist zu erwarten, dass sowohl viele kleinere Ereignisse als auch einige Extremereignisse übermittelt werden. In vielen Fällen wird es so sein, dass die internen Daten und die externen Daten aus öffentlichen Quellen nur einen geringen Überschneidungsbereich haben werden. Dann können Daten aus Datenkonsortien für die Plausibilisierung und die Kalibrierung der Daten aus öffentlichen Quellen verwendet werden.

Für die Verwendung externer Daten aus Datenkonsortien sind mindestens die gleichen Informationen wie auch bei den internen Verlustdaten notwendig. Damit ein Unternehmen Zugriff auf die Daten erlangen kann, muss es im entsprechenden Konsortium Mitglied sein.

Bei der praktischen Umsetzung eines Konsortiums ist die Einigung auf einen gemeinsamen Erhebungsstandard die größte Herausforderung. Ein Beispiel wie ein solcher aussehen könnte liefert das ORX-Datenkonsortium in ORX Association (2004).

Für die Erstellung von Szenarien sind solche Daten häufig nur bedingt verwendbar, da die Beschreibungen eingetretener Verluste – wenn sie überhaupt übermittelt werden – sehr allgemein gehalten sind, damit die Anonymität gewährleistet werden kann. Daher könnte versucht werden sich auf einen Standard zu einigen, bei dem mit zunehmender Höhe des Verlustes oder wenn dieser der Öffentlichkeit ohnehin schon bekannt

geworden ist die Beschreibungen ausführlicher werden, um so bei der Szenarioanalyse zu unterstützen.

Ebenso wie auch bei den externen Daten aus öffentlichen Quellen stellt sich die Frage, ob die Daten direkt verwendet werden können oder ob sie vorher bezüglich ihrer Höhe und ihrer Häufigkeit skaliert werden müssen. Im Gegensatz zu diesen Daten haben die Unternehmen, die an einem Konsortium teilnehmen, selbst Interesse daran, zu erfahren, wie Verlustdaten mit der Größe oder anderen Parametern eines Instituts skalieren und könnten daher bereit sein, selbst diesbezügliche Forschungen zu betreiben oder ausgewählten Forschern Zugang zu den Daten zu gewähren.

2.5. Sonstige Daten

2.5.1. Risk-Assessment

Um das operationelle Risiko umfassend berücksichtigen zu können, ist die Analyse der Riskolandschaft unabdingbar. Sie ist die Basis für sämtliche, nach dem Wirtschaftlichkeitsprinzip vorgeschlagenen Maßnahmen, welche die Vorbeugung, die mögliche Reduktion des Risikopotenziels sowie die Risikofinanzierung einschließen (Kaufmann und Dröse 2000). Dadurch stellt sie einen fundamentalen Beitrag zur Identifizierung und zum Management operationeller Risiken dar. Durch intensive Beschäftigung mit diesen Risiken wird in den verschiedenen Unternehmensbereichen das Bewusstsein dafür verbessert und teilweise sogar erst geschaffen, welchen wesentlichen Risiken ein Bereich ausgesetzt ist.

Während Verlustdaten vergangenheitsorientiert und Szenarioanalysen²⁸ zukunftsorientiert sind, liegt der Fokus von Assessments in der Ermittlung der aktuell bestehenden Risikolage und stellt daher einen weiteren wichtigen Baustein zur Ermittlung der voll-

²⁸vgl. Abschnitt 2.5.3

ständigen Risikoprofils einer Bank dar.

Der direkte quantitative Zusammenhang zwischen einem Assessment und dem notwendigen Risikokapital der Bank ist wegen dessen qualitativen Charakters nicht zu ermitteln. Wenn eine Quantifizierung jedoch anhand quantitativer Quellen oder anhand der Vorgaben des Standardansatzes von Basel II²⁹ bereits durchgeführt wurde, kann ein gutes oder schlechtes Assessment zu einem Ab- oder Zuschlag vom bzw. zum ökonomischen Kapital führen.

Im Jahre 1999 wurden in der Umfrage (RMA u. a. 1999, S. 56ff) vier verschiedene Ansätze herausgestellt, ein Assessment durchzuführen:

- Fragebögen mit vorgegebenen Bewertungen. Bei dieser Form werden Fragen gestellt und Antwortmöglichkeiten vorgegeben, die von den untersuchten Bereichen ausgewählt werden sollen.
- Offene Fragen. Dabei werden Fragen über die Art und Weise des Risikocontrollings gestellt, die ausführlich zu beantworten sind.
- Moderierte Workshops. Dabei kann auf die Fragebögen verzichtet werden und Mitarbeiter verschiedener Bereiche diskutieren unter der Leitung eines Risikomanagers über die Identifizierung und Bewertung von Risiken.
- Unabhängige Assessments. Bei dieser Form wird eine umfassende Begutachtung aller Prozesse, Risiken und entsprechender Kontrollen von einer dritten Stelle³⁰ durchgeführt.

Cruz (Cruz 2002, Seiten 33ff) schlägt in Anlehnung an die Delphi Methode von Linstone (Linstone und Turoff 1975) zwei Wege zur Implementierung vor, die eine Kombination

²⁹vgl. 2.6.1

³⁰z.B. der Revision

der oben genannten Bausteine darstellen:

Bei der konventionellen Delphi Methode werden von einem Mittler gestaltete Fragebögen in mehreren Runden beantwortet und nach jeder Frage kann der Fragebogen modifiziert werden, wobei die Antwortenden die Gelegenheit bekommen, ihre Antworten auf Basis der anderen Antworten zu überdenken. Bei der Echtzeit Delphi Methode wird im Wesentlichen dieser Mittler durch ein Computersystem ersetzt. Dadurch werden prozessuale Verzögerungen reduziert.

Neben der prozessualen Umsetzung sind wichtige Herausforderungen an die Assessments zum Einen die Entwicklung eines geeigneten Fragenkataloges, der die Risikolage der Bank adäquat wiedergibt und zum Anderen die Standardisierung der Antworten verschiedener unterschiedlich risikofreudiger Mitarbeiter, damit diese miteinander verglichen werden können.

2.5.2. Risikoindikatoren

Risikoindikatoren sind regelmäßig zu erhebende Kennzahlen, von denen vermutet wird, dass sie mit der Risikolage der Bank zusammenhängen. Anhand der Analyse ihres zeitlichen Verlaufs können sie ein Frühwarnsystem für potenzielle Risiken darstellen. Laut RMA u. a. (1999) haben bereits im Jahr 1999 50% der untersuchten Institute diese für die Messung operationeller Risiken verwendet.

Ziel der Verwendung von Risikoindikatoren ist es, die Risikolage der Bank zu Steuerungs- und Kontrollzwecken zu reflektieren und wesentliche Risiken frühzeitig zu identifizieren sowie qualitativ zu bewerten. Ferner soll durch die historische Vergleichsmöglichkeit der Risikoindikatoren die Qualität des Risikomanagementprozesses beurteilt werden. Dabei ist insbesondere die mögliche Korrelation zwischen Verlustdaten und Risikoindikatoren zu beachten. Der Fokus von Risikoindikatoren liegt auf häufigen Verlusten mit

geringer Auswirkung. Weiterhin sollen die Indikatoren ähnlich wie die Ergebnisse des Risk-Assessments Einfluss auf das Quantifizierungssystem der Bank haben.

Risikoindikatoren müssen in den meisten Fällen von den Mitarbeitern manuell ermittelt werden. Teilweise ist die automatisierte Erhebung möglich. Es wird vermutet, dass ungefähr 99% der Verluste aus operationellen Risiken manuell erfasst werden müssen (Leander 2002). Für die praktische Umsetzung ist weiterhin die grundsätzliche Datenverfügbarkeit und der Aufwand für die Ermittlung relevant. Beispiele für Risikoindikatoren zur Beschreibung operationeller Risiken sind (Klomfass und Quandt 2001):

- Personal
 - Quote offener Stellen
 - Anteil externer Mitarbeiter
 - geleistete Überstunden
 - Anzahl krimineller Handlungen
- Technologie
 - Anzahl und Dauer Systemausfälle
 - ungenügende Systemperformanz
 - Systemsicherheit
 - Qualität 1st Level Support
- Prozesse/Organisation
 - Qualität Arbeitsplatzausstattung
 - unzureichend dokumentierte Geschäfte/Verträge

- Fehlerquote pro Aktivität
- Anzahl manueller Schnittstellen

Dabei ist die wesentliche Herausforderung an einen Risikoindikator die Relevanz für die Risikolage der Bank. Bei der erstmaligen Implementierung von Risikoindikatoren kann diese lediglich vermutet werden. Notwendig ist an dieser Stelle eine regelmäßige Überprüfung und ein Abgleich des zeitlichen Verlaufs der Risikoindikatoren und der Veränderung der Häufigkeit und Höhe von eingetretenen Verlusten.

2.5.3. Szenarioanalysen

Szenarien sind hypothetische Folgen von Ereignissen, die konstruiert werden, um die Eintrittswahrscheinlichkeit und die eventuellen Schadenshöhen noch nicht eingetretener aber möglicher Verlustereignisse zu schätzen und zu analysieren.

Szenarioanalysen können einen fundamentalen Beitrag zum Verständnis und zum Management operationeller Risiken leisten. Sie vertiefen das Verständnis für die Entstehung von Risiken und wurden bereits erfolgreich in anderen Industrien eingesetzt (Fahey und Randall 1998; Perrow 1984; Godet 1987; Reason 1997). In ETH-UNS Fallstudienbüro (2001) werden Szenarioanalysen kurz dargestellt und erläutert. Einen umfassenden Überblick über die möglichen Techniken zur Anwendung der Analyse geben Götze (1993) und Mißler-Behr (1993). Die klassische Beschreibung liefert Kahn und Wiener (1967). Dabei fokussiert diese Literatur eher auf kausale Zusammenhänge und die Möglichkeit, die Zukunft einer Unternehmung durch strategische Planung zu beeinflussen. Im Rahmen der Quantifizierung operationeller Risiken sollte jedoch eher die Schätzung von Eintrittswahrscheinlichkeiten und Schadenhöhen im Vordergrund stehen.

Die Einführung von Szenarioanalysen stellt die Umsetzung der Idee dar, dass Experten des Unternehmens verlässliche Erfahrungen über die Risiken ihres Geschäftes haben

und dass diese Erfahrungen von den internen Verlustdaten nicht oder nicht vollständig abgedeckt werden.

Durch die Durchführung von Szenarioanalysen in den verschiedenen Bereichen der Bank, lässt sich mehr über potenzielle Risiken erfahren. Insbesondere die Beschäftigung des Managements mit solchen Szenarien kann bei intensiver Durchführung zu einer fundamentalen Verbesserung des Risikobewusstseins führen. Sogenannte „scenario based advanced measurement approaches“ (sbAMA) beruhen in wesentlichen Teilen auf Szenarioanalysen. Dabei wird vermutet, dass Experten aufgrund qualitativer und teilweise auch quantitativer Einschätzungen das tatsächliche Risiko, dem eine Bank ausgesetzt ist, angemessen beurteilen können.

In Basel Committee on Banking Supervision (2004) werden qualitative Anforderungen beschrieben, die erfüllt sein müssen, damit eine Szenarioanalyse aufsichtlich anerkannt wird. Wichtiger Punkt ist eine weitgehende Standardisierung über alle Bereiche der Bank hinweg und eine ausführliche Dokumentation der im Rahmen der Szenarioanalyse durchgeführten Prozesse.

Damit Szenarioanalysen durchgeführt werden können, ist die Mitwirkung von Experten aus verschiedenen Bereichen erforderlich. Nur diese kennen ihren eigenen Bereich so genau, dass sie in der Lage sind, angemessene Schätzungen durchzuführen. Dabei sind Häufigkeits- oder Höhenverteilungen oder entsprechende Parameter vorgegebener Verteilungen zu schätzen. Ebenfalls muss für eine Quantifizierung sichergestellt werden, dass durch die Szenarioanalyse alle relevanten Szenarien beschrieben worden sind. In der Praxis wird keine dieser Bedingungen tatsächlich vollständig zu erfüllen sein.

Die Sicherheit zu erhalten, dass alle relevanten Szenarien geschätzt wurden, ist unmöglich, denn niemand kann Dinge schätzen, die er nicht kennt, die noch nie eingetreten

sind und deren Eintreten auch jenseits aller Vorstellungskraft liegt³¹. Weiterhin ist die Schätzung, ob ein Extremereignis z.B. alle 1.000 oder alle 10.000 Jahre eintritt auch nicht exakt möglich und selbst wenn diese Information verfügbar wäre, ist dies noch nicht für die Ermittlung einer Verteilungsfunktion ausreichend. Schließlich ist die Schätzung einer Verlusthöhenverteilung – auch wenn hier noch am leichtesten Vergleiche mit anderen Verlusten gezogen werden können – nicht exakt möglich. Ansonsten könnte die gesamte Quantifizierung lediglich anhand von Szenarioanalysen durchgeführt werden.

Die größte Schwierigkeit der Durchführung der Szenarioanalysen liegt in der Auswahl der die Schätzungen durchführenden Mitarbeiter. Während der Szenarioanalyse sollen von diesen Schätzungen durchgeführt werden. Dabei wäre es wünschenswert aus den Ergebnissen und Schätzungen erwarteter und unerwarteter Verluste Input für die Berechnung des OpVaR³² gewinnen zu können. Einerseits ist es nun notwendig, dass die Experten den zu schätzenden Bereich sehr genau kennen. Dies spricht dafür, langjährige Mitarbeiter eines Bereichs einzusetzen. Andererseits haben diese das Interesse, das Risikokapital für ihren Bereich zu minimieren. Daher ist zu erwarten, dass die Schätzungen häufig zu niedrig ausfallen werden.

Im Rahmen des Managements operationeller Risiken ist dieser Interessenkonflikt zu minimieren. Im Rahmen dieser Arbeit wird auf diesen Aspekt jedoch nicht weiter eingegangen. Hier ist weitere Forschungsarbeit notwendig.

2.5.4. Beinaheverluste

Beinaheverluste sind Ereignisse, die zu einem Verlust geführt haben könnten, es aber nicht haben (Reynolds und Syer 2002). Dafür kann es verschiedene Gründe geben. Zunächst kann es sein, dass die internen Kontrollen effizient funktioniert haben, so dass

³¹als Beispiel sei hier der Angriff auf das World Trade Center genannt

³²vgl. Definition 3.1

der Verlust abgewendet werden konnte. Daher ist die Kenntnis über diese Verlustart interessant, da somit die Qualität der internen Kontrollen nachgewiesen werden kann. Eine andere Möglichkeit ist, dass der Verlust deshalb nicht eingetreten ist, da glückliche Umstände dies verhindert haben. Dann sollte dieses Ereignis ebenfalls analysiert werden, da beim nächsten Mal diese glücklichen Umstände eventuell nicht eintreten werden und interne Prozesse dafür sorgen sollten, dass dennoch kein Verlust für das Unternehmen entsteht.

2.5.5. Hilfsdaten

Für die konkrete Umsetzung eines Modells zur Berechnung operationeller Risiken werden noch eine Reihe weiterer Informationen benötigt, die in diesem Abschnitt kurz erläutert werden

1. Verrechnung interner Leistungen

Bei Verwendung des Standardansatzes³³ müssen sowohl die Bruttoerträge als auch die durch Risikoereignisse entstandenen Kosten auf die vorgegebenen Business Lines abgebildet werden. Bei der Verwendung ambitionierter Ansätze³⁴ ist dies grundsätzlich nicht notwendig, allerdings ist auch hier eine Abbildung von Cost-centern auf Profitcenter sinnvoll, damit die entstehenden Kosten auch durch entsprechende Gewinne verrechnet werden können.

2. Wechselkurse

Damit Verluste miteinander verglichen werden können, ist es notwendig, diese auf einen gemeinsamen Stand zu bringen. Dazu müssen in fremden Währungen angefallene Verluste in die heimische Währung umgerechnet werden. Ebenso muss

³³vgl. Abschnitt 2.6.2

³⁴vgl. Abschnitt 2.6.3

der Inflation Rechnung getragen werden, so dass in der Vergangenheit angefallene Beträge auf heutige Preise umgerechnet werden sollten. Dabei werden erneut die bereits bei den Verlustdaten angesprochenen Herausforderungen bzgl. der zu verwendenden Zeitpunkte relevant.

3. Versicherungen

Viele – insbesondere kleinere, häufige – Verluste aus operationellen Risiken können typischerweise durch Versicherungen abgedeckt werden. Damit diese in den Risikoberechnungen verwendet werden können, sind von Basel vorgegebene grundsätzliche Anforderungen zu erfüllen (Basel Committee on Banking Supervision 2004, Absatz 678). Entsprechende Informationen sind zu sammeln, die es erlauben, die Höhe der zu erwartenden Versicherungsleistungen je Schadenfall, den entsprechenden Selbstbehalt oder Versicherungslimits zu berechnen. Es kann sein, dass die Informationen lediglich auf aggregierter Ebene verfügbar sind und auch auf dieser Ebene verwendet werden können.

Bei der Entwicklung von Modellen ist zu beachten, dass Extremereignisse häufig nicht versicherbar sind und selbst wenn sie versichert sein sollten, die Versicherungen nicht in der Lage oder nicht Willens sind, den Schaden schnell zu regulieren. Selbst wenn eine Versicherung in einem solchen Fall später dazu verurteilt werden sollte, für die Regulierung eines Schadens aufzukommen, kann es vorkommen, dass die Bank aufgrund der Verzögerungen in Liquiditätsengpässe gerät oder weitere nicht versicherte Verluste aufgrund des Reputationsverlustes erleidet.

2.6. Berechnungsansätze

In diesem Abschnitt werden die in Basel Committee on Banking Supervision (2004) erwähnten Ansätze für die Berechnung des notwendigen Eigenkapitals dargestellt. Der Basisindikatoransatz und der Standardansatz werden nur der Vollständigkeit halber aufgeführt, da beide vermutlich von den meisten Banken zunächst für die Berechnung verwendet werden. Sie sind jedoch für eine quantitative Betrachtung ungeeignet, da sie lediglich eine Berechnungsmethode darstellen, deren Annahmen und Parameter extern vorgegeben werden und keinerlei Sensitivität bezüglich des operationellen Risikos erwarten lassen.

2.6.1. Basisindikatoransatz

Beim Basisindikatoransatz ist ein von der Aufsicht festzulegender Prozentsatz α des durchschnittlichen jährlichen positiven Bruttoertrages der vergangenen drei Jahre als vorzuhaltendes Risikokapital notwendig. Ist der Bruttoertrag eines oder mehrerer Jahre negativ, werden diese aus der Betrachtung herausgenommen. Das Kapital berechnet sich also wie folgt:

$$K_{\text{BIA}} = \frac{\sum_{n=1}^N \max(Gl_n, 0)\alpha}{m} \quad (2.1)$$

mit

$$K_{\text{BIA}} = \text{Kapital unter Basisindikatoransatz} \quad (2.2)$$

$$Gl_n = \text{Bruttoertrag des } n\text{-letzten Jahres} \quad (2.3)$$

$$m = \begin{array}{l} \text{Anzahl der Jahre innerhalb der letzten} \\ N \text{ Jahre mit positivem Bruttoertrag} \end{array} \quad (2.4)$$

$$\alpha = 15\% \quad (2.5)$$

$$N = \text{Anzahl der einzubeziehenden Jahre} = 3 \quad (2.6)$$

2.6.2. Standardansatz

Das Kapital beim Standardsansatz wird ähnlich berechnet, wie das Kapital für den Basisindikatoransatz. Die Bank wird in acht Geschäftsfelder (vgl. Abschnitt 2.3.1) aufgeteilt und für jedes muss ein gewisser Prozentsatz β_i des jeweiligen Bruttoertrages als Risikokapital vorgehalten werden. Diese Prozentsätze werden vom Baseler Komitee, wie in Tabelle 2.3 dargestellt, vorgeschlagen. Ein negatives Risikokapital eines Geschäftsfeldes kann mit dem positiven Risikokapital anderer Geschäftsfelder innerhalb des gleichen Jahres verrechnet werden. Für jedes Jahr wird jedoch für die Gesamtbank mindestens das Risikokapital 0 angesetzt. Das notwendige Kapital wird daher wie folgt berechnet:

$$K_{\text{STA}} = \frac{\sum_{n=1}^N \max(\sum_{i=1}^I Gl_{ni}\beta_i, 0)}{N} \quad (2.7)$$

Geschäftsfeld	β -Faktor
Unternehmensfinanzierung/-beratung (Corporate Finance)	$\beta_1=18\%$
Handel (Trading & Sales)	$\beta_2=18\%$
Privatkundengeschäft (Retail Banking)	$\beta_3=12\%$
Firmenkundengeschäft (Commercial Banking)	$\beta_4=15\%$
Zahlungsverkehr und Wertpapierabwicklung (Payment & Settlement)	$\beta_5=18\%$
Depot- und Treuhandgeschäfte (Agency Services)	$\beta_6=15\%$
Vermögensverwaltung (Asset Management)	$\beta_7=12\%$
Wertpapierprovisionsgeschäft (Retail brokerage)	$\beta_8=12\%$

Tabelle 2.3.: Geschäftsfelder

mit

$$K_{\text{STA}} = \text{Kapital unter Standardansatz} \quad (2.8)$$

$$Gl_{ni} = \begin{array}{l} \text{Bruttoertrag des } n\text{-letzten Jahres} \\ \text{in Geschäftsfeld } i \end{array} \quad (2.9)$$

$$\beta_i = \beta\text{-Faktor des Geschäftsfeldes } i \quad (2.10)$$

$$I = \text{Anzahl der Geschäftsfelder} = 8 \quad (2.11)$$

$$N = \text{Anzahl der einzubeziehenden Jahre} = 3 \quad (2.12)$$

Als Variation des Standardansatzes gibt es den Alternativen Standardansatz. Bei diesem entsprechen die Eigenkapitalanforderungen denen des Standardansatzes, abgesehen von den beiden Geschäftsfeldern Privatkundengeschäft und Firmenkundengeschäft. Bei diesen wird das notwendige Kapital nach folgender Formel berechnet:

$$K_{\text{RB,CB}} = \beta_{\text{RB,CB}} m L A_{\text{RB,CB}} \quad (2.13)$$

mit

$$K_{\text{RB,CB}} = \begin{array}{l} \text{Eigenkapitalanforderung für das Privat- (RB)} \\ \text{bzw. Firmenkundengeschäft (CB)} \end{array} \quad (2.14)$$

$$\beta_{\text{RB,CB}} = \beta\text{-Faktor für das Privat- (RB) bzw. Firmenkundengeschäft (CB)} \quad (2.15)$$

$$LA_{\text{RB,CB}} = \left\{ \begin{array}{l} \text{das gesamte jährlich ausstehende Volumen der Privatkundendarlehen} \\ \text{und -kredite (RB) bzw. Firmenkundendarlehen und -kredite (ohne} \\ \text{Risikogewichtung und ohne Abzug von Wertberichtigungen) im} \\ \text{Durchschnitt der letzten drei Jahre.} \end{array} \right. \quad (2.16)$$

$$m = 0.035 \quad (2.17)$$

Damit eine Bank die Zulassung zur Verwendung des Standardansatzes erhält, werden von der Aufsicht eine Reihe von quantitativen und qualitativen Anforderungen an das Risikomanagement im Allgemeinen und den Risikomanagementprozess im Besonderen gestellt werden. Diese werden in dieser Arbeit nicht weiter diskutiert.

2.6.3. Ambitionierte Messansätze

Sofern eine Bank weitgehende qualitative und quantitative Anforderungen erfüllt, die in Basel Committee on Banking Supervision (2004) explizit vorgegeben werden und die sich insbesondere auf die Konsistenz, die Validität und die Risikosensitivität beziehen, kann Ihr gestattet werden, einen Ambitionierten Messansatz (AMA) zu verwenden. Von großen, international tätigen Banken wird erwartet, dass sie die entsprechenden Anstrengungen unternehmen, um sich für die Anwendung des AMA zu qualifizieren.

Bei der Anwendung ambitionierter Messansätze ergibt sich die Höhe des Risikokapitals aus dem internen System der Bank. Zunächst ist nicht zu erwarten, dass die nationalen Aufsichtsinstanzen konkrete Regeln für die Umsetzung der komplexeren Ansätze vorgeben werden (Goodbody 2003), wie dies z.B. bei Kreditrisiken der Fall ist. Im neuen Kapitalakkord finden sich diesbezüglich auch keinerlei Vorgaben. Dies mag daran liegen, dass erst einmal die Entwicklung eines Industriestandards abgewartet werden soll und die Aufsicht mangels besseren Wissens nicht in diese Entwicklung eingreifen möchte. Daher wird von den Banken die sich für den AMA qualifizieren möchten erwartet, dass diese selbstständig Modelle zur Quantifizierung entwickeln.

Mit der Einführung des AMA zeigt Basel darüber hinaus eine erstaunliche Aufgeschlossenheit gegenüber stochastischen Modellen. Denn die Möglichkeit, operationelle Risiken auf dieser Basis zu berechnen, geht weit über die für die Bestimmung von Kreditrisiken erlaubten Verfahren hinaus. Dies ist umso bemerkenswerter, als die Datengrundlage für operationelle Risiken im Allgemeinen als dürftiger anzusehen ist als die für Kreditrisiken. (Mathmann 2003)

Bezüglich der Quantifizierung operationeller Risiken im neuen Kapitalakkord ist noch kein Industriestandard verfügbar. Es gibt jedoch Modelle – wie z.B. das kollektive Modell der Versicherer – die in der aktuellen Literatur häufiger erwähnt werden. Diese werden im nächsten Kapitel vorgestellt und bilden auch die Basis für die Bestimmung der Konfidenzintervalle.

3. Quantifizierung operationeller Risiken – typische Modellierungsansätze

Das Baseler Komitee beweist mit dem neuen Akkord eine erstaunliche Aufgeschlossenheit gegenüber der eigenen Entwicklung von Modellen innerhalb der Kreditinstitute. Insbesondere im Bereich der operationellen Risiken werden keinerlei explizite Berechnungsvorschriften festgelegt. Dies mag damit zusammen hängen, dass sich bisher kein Industriestandard für die Berechnung operationeller Risiken etabliert hat. Die Entwicklung eines solchen soll auf diese Weise unterstützt werden.

Dabei ist die Berechnung von Verlustverteilungen anhand von historischen Daten eine Herausforderung, der sich Versicherungen in der Vergangenheit bereits erfolgreich gestellt haben. Ebenfalls ist die Berechnung von Ausfallwahrscheinlichkeiten anhand qualitativer Daten eine Aufgabe, die sich in ähnlicher Weise bei der Betrachtung von Kreditrisiken stellt. Auf diese Erkenntnisse kann bei der Entwicklung neuer Modelle zurückgegriffen werden; jedoch treten insbesondere bezüglich der gemeinsamen Betrachtung qualitativer und quantitativer Einflussfaktoren und der Endogenität des Risikos neue Herausforderungen auf, die bei der Entwicklung berücksichtigt werden müssen.

463. Quantifizierung operationeller Risiken – typische Modellierungsansätze

In diesem Zusammenhang hat sich bereits eine Vielfalt unterschiedlichster qualitativer und quantitativer Modelle entwickelt. Dabei werden nicht alle Verfahren und insbesondere nicht deren Details veröffentlicht, da sie von den Banken selbst entwickelt wurden und diese häufig an einer Veröffentlichung nicht interessiert sind, da sie sich durch die Geheimhaltung einen Wettbewerbsvorteil versprechen. Eine vollständige geordnete Übersicht über die aktuell am Markt verfügbaren und veröffentlichten sowohl qualitativen als auch quantitativen Verfahren ist bisher noch nicht erschienen. Eine solche würde den Umfang dieser Arbeit bei weitem übersteigen.

In diesem Kapitel wird zunächst der Begriff „Risiko“ untersucht und der Value-at-Risk (VaR) eingeführt. Danach wird ein typisches, in wesentlichen Teilen aus der Versicherungswirtschaft stammendes, Verfahren eingeführt, mit welchem operationelle Risiken in Banken quantifiziert werden. Schließlich wird gezeigt, wie die Höhe des Risikos mit Hilfe einer Monte-Carlo-Simulation ermittelt werden kann.

3.1. Value-at-Risk

Die grundsätzliche Idee, dass Risiken einen wichtigen Einfluss auf ökonomische Entscheidungen haben können, hat bereits Knight 1921 formuliert (Knight 1921). Dennoch gibt es bis heute „keinen Begriff des Risikos, der wissenschaftlichen Ansprüchen genügen könnte“ (Luhmann 1990, Seite 14). Im heutigen Sprachgebrauch hat sich die Bedeutung „danger of loss“ (Jorion 1997) durchgesetzt, obwohl Risiko in der Finanzierungslehre eher als „dispersion of unexpected outcomes due to movements in financial variables“ (Jorion 1997) definiert wird. Für den weiteren Verlauf dieser Arbeit wird Risiko definiert als das „Potenzial für einen auftretenden Verlust“.

Damit Risiken nicht nur definiert, sondern auch gemessen werden können, hat sich in den letzten Jahren der „Value-at-Risk“ (VaR) als Industriestandard etabliert. Dieser

beschreibt den größten Verlust der mit einer vorgegebenen Wahrscheinlichkeit, dem Konfidenzniveau, innerhalb eines vorgegebenen Zeitraumes nicht überschritten wird. Auch für die Berechnung operationeller Risiken wird sich vermutlich ein „operational-Value-at-Risk“ (OpVaR) durchsetzen, da dieser in Basel Committee on Banking Supervision (2004) als Vergleichsmaßstab für eine Quantifizierung festgelegt wird. Im Unterschied zum Marktrisiko, bei dem grundsätzlich Kursverläufe modelliert werden, werden bei der Modellierung operationeller Risiken Verlustverteilungen verwendet. Daher weicht die Definition eines „operational-Value-at-Risk“ (OpVaR) von der typischen Definition des VaR leicht ab.

Definition 3.1 (Value at Risk) *Sei S der Gesamtverlust im im Zeitraum T . Sei S verteilt mit $F_S(x)$ und sei $F_S^{-1}(\bullet)$ die Umkehrfunktion von F . So ist der OpVaR zum Konfidenzniveau α definiert als:*

$$OpVaR(\alpha) = F_S^{-1}(\alpha) \quad (3.1)$$

Wesentlicher Vorteil der Messung eines VaR ist der Erhalt einer einzelnen Zahl, durch die das Risiko charakterisiert wird. Auf diese Weise kann das so definierte Risiko vergleichbar gemacht und auch eine Idee von diesem einer breiteren Masse zugänglich gemacht werden. Mit dieser Vereinfachung geht zwangsweise ein Verlust an Informationen einher. Es fehlt jede sonstige Information, die eine Verlustverteilung liefern kann.

3.2. Expected Shortfall

Bei Nutzung des VaR fehlt insbesondere jegliche Information darüber, wie groß der Verlust in Extremereignissen werden kann. Eine weitere, häufig genutzte Möglichkeit,

das Risiko eines Portfolios darzustellen, die diesen Mangel¹ ausgleicht ist der Expected Shortfall (ES). Der ES stellt den erwarteten Verlust unter der Bedingung dar, dass der VaR überschritten wird.

Definition 3.2 (Expected Shortfall) *Sei S der Gesamtverlust im im Zeitraum T . Sei S verteilt mit $F_S(x)$ und $OpVaR(\alpha)$ der VaR zum Konfidenzniveau α . Dann ist der ES zum Konfidenzniveau α definiert als:*

$$ES_{OpRisk}(\alpha) = E(F_S(x) | F_S(x) > OpVaR(\alpha)) \quad (3.2)$$

Die Messung sowohl des VaR als auch des ES liefern somit eine angemessene Grundlage zur Interpretation des Risikos. In dieser Arbeit werden daher stets beide Größen ermittelt und angegeben.

3.3. Verlustverteilungsansatz

In diesem Abschnitt wird ein einfacher Verlustverteilungsansatz beschrieben, der so die Basis für viele AMA-Ansätze bilden wird. Er wird unter anderem in ABN AMRO u. a. (2003) beschrieben. Die theoretischen Grundlagen stammen im Wesentlichen aus der Modellierung von Versicherungen und finden sich bei Klugman u. a. (1998).

Beim Verlustverteilungsansatz oder auch Loss Distribution Approach (LDA) werden im Wesentlichen historische Verlustdaten zur Quantifizierung herangezogen. Teilweise können noch andere qualitative Daten Verwendung finden, die jedoch lediglich eine untergeordnete Rolle spielen. Ziel dieser Arbeit ist die Berechnung von Konfidenzintervallen für die quantitativen Schätzungen. Daher wird der eventuelle Einfluss qualitativer Da-

¹Für eine ausführliche Darstellung der Vorteile des Expected Shortfall gegenüber dem Value-at-Risk vgl. Artzner u. a. (1999).

ten nicht weiter berücksichtigt. Es wird weiterhin angenommen, dass als Modell für die Schätzungen das kollektive Modell der Versicherungen angewendet wird.

Definition 3.3 (Kollektives Risikomodell) *Ein kollektives Risikomodell beschreibt den Gesamtverlust als eine Summe S von N Verlusten $(X_1 \dots X_N)$. Somit gilt $S = \sum_{i=1}^N X_i$. Es wird angenommen, dass alle Zufallsvariablen unabhängig sind und dass die X_i identisch verteilt sind.*

3.3.1. Bezeichnungen

Die Darstellung der Verteilungen lehnt sich an Klugman u. a. (1998) an. Es bedeuten:

$$P[\cdot] = \text{Eintrittswahrscheinlichkeit} \quad (3.3)$$

$$E[\cdot] = \text{Erwartungswert} \quad (3.4)$$

$$\text{Var}[\cdot] = \text{Varianz} \quad (3.5)$$

$$\phi(x) \sim N(0, 1) \quad (\text{Standardnormalverteilung}) \quad (3.6)$$

$$\Phi(z) = \int_{-\infty}^z dt \phi(t) \quad (3.7)$$

$$\Gamma(\alpha) = \int_0^{\infty} t^{\alpha-1} e^{-t} dt, \quad \alpha > 0 \text{ (Gammafunktion)} \quad (3.8)$$

$$\Gamma(\alpha; x) = \frac{1}{\Gamma(\alpha)} \int_0^x t^{\alpha-1} e^{-t} dt, \quad \alpha > 0, x > 0 \quad (3.9)$$

$$(3.10)$$

Definition 3.4 (Normalverteilung) *Eine Zufallsvariable X ist $N(\mu, \sigma)$ -verteilt (normalverteilt), wenn für ihre Dichtefunktion f gilt:*

$$f_{\mu, \sigma^2}(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{\sigma^2}} \quad (3.11)$$

Für die Verteilungsfunktion der Normalverteilung schreiben wir auch $\Phi_{\mu,\sigma}(z)$ bzw. $\Phi(z)$ falls die Parameter $\mu = 0$ und $\sigma = 1$ sind. Die entsprechende Verteilung heißt dann Standardnormalverteilung.

3.3.2. Verlusthäufigkeit

Die Häufigkeitsverteilung gibt an, wie groß die Wahrscheinlichkeit p dafür ist, dass im Zeitraum t genau N Verluste auftreten.

$$p_k = P(N = k) \quad (3.12)$$

Bei der Wahl eines parametrischen Ansatzes stehen verschiedene Verteilungen wie z.B. die Poisson- oder die Binomialverteilung zur Verfügung. Im weiteren Verlauf dieser Arbeit beschränken wir uns auf die Poissonverteilung die Erweiterung auf andere Verteilungen wäre jedoch denkbar und bleibt späteren Forschungen vorbehalten.

Die Poissonverteilung wird für die Modellierung von Verlusthäufigkeiten verwendet. Sie ist für die natürlichen Zahlen und 0 definiert. Die Poissonverteilung mit Parameter λ hat die Wahrscheinlichkeitsfunktion

$$p_k = \frac{e^{-\lambda} \lambda^k}{k!} \quad (3.13)$$

für $k = 0, 1, 2, \dots$ Mittelwert und Varianz sind identisch und entsprechen dem Parameter λ .

Wenn eine empirische Zeitreihe vorliegt und Häufigkeitsschätzungen durchgeführt werden sollen, sei n_k die Anzahl der Zeiteinheiten, in der genau k Verluste eingetreten sind. Sowohl der Momentenschätzer als auch der Maximum-Likelihood-Schätzer für λ lassen sich nun berechnen durch:

$$\hat{\lambda} = \frac{\sum_{k=0}^{\infty} k n_k}{\sum_{k=0}^{\infty} n_k} \quad (3.14)$$

Die Poissonverteilung hat einige interessante Eigenschaften. Da gerade bei operativen Risiken nicht bekannt ist, ob tatsächlich alle Daten auch innerhalb einer Risikokategorie aus derselben Verteilung mit denselben Parametern stammen, werden hier zwei Eigenschaften herausgestellt, die sie gerade für diese Zwecke prädestinieren.

Satz 3.1 (Summe poissonverteilter Variablen) *Seien N_1 und N_2 unabhängig und poissonverteilt mit Parametern λ_1 und λ_2 . Dann ist die Summe $N_1 + N_2$ ebenfalls poissonverteilt mit Parameter $\lambda_1 + \lambda_2$.²*

Satz 3.2 (Klassen poissonverteilter Variablen) *Sei N poissonverteilt mit Parameter λ . Es könne jedes Ereignis unabhängig von den anderen Ereignissen einer von m Klassen mit Wahrscheinlichkeit $p_1 \dots p_m$ zugeordnet werden. Dann sind die $N_1 \dots N_m$ Ereignisse, die den jeweiligen Klassen zugeordnet werden unabhängig voneinander und Poissonverteilt mit den Parametern $\lambda_{p_1} \dots \lambda_{p_m}$.³*

Diese Eigenschaften sind hauptsächlich für die Ermittlung des datengenerierenden Prozesses relevant. Im weiteren Verlauf dieser Arbeit wird dieser als bekannt vorausgesetzt. Prinzipiell können die durchgeführten Schätzungen und Simulationen ebenfalls mit anderen Häufigkeitsverteilungen durchgeführt werden. Die Poissonverteilung wurde dabei aufgrund ihrer einfachen Eigenschaften ausgewählt.

3.3.3. Verlusthöhe

Die Verlusthöhenverteilung beschreibt die Verteilung der Höhe einzelner Verluste. Damit sie für die Modellierung von Verlusthöhen von Versicherungen geeignet sind, sollten

²für den Beweis siehe (Klugman u. a. 1998, Seite 202)

³für den Beweis siehe (Klugman u. a. 1998, Seite 203)

523. Quantifizierung operationeller Risiken – typische Modellierungsansätze

sie mindestens allen nicht negativen reellen Zahlen eine Wahrscheinlichkeit zuordnen⁴, ausreichend glatt sein und ggf. schwere Ränder, d.h. eine Kurtosis von mehr als drei haben⁵.

Wichtiges Ziel aller Modellierung ist die Berechnung sehr hoher Quantile⁶. Daher ist das Verhalten der Verteilungen an ihrem rechten Rand von besonderer Bedeutung.

Die bisher bei der Quantifizierung operationeller Risiken am häufigsten verwendete Verteilungsfunktion ist die Lognormalverteilung, eine Verteilung, deren Logarithmus normalverteilt ist. Diese wird im quantitativen Teil sowohl für die Generierung der Verlustdaten als auch für entsprechende Schätzungen verwendet.

Definition 3.5 (Lognormalverteilung) *Eine Zufallsvariable X ist lognormalverteilt mit Parametern μ und σ , wenn für ihre Dichtefunktion $f_X(x)_{\mu,\sigma}$ gilt:*

$$f_X(x)_{\mu,\sigma} = \frac{1}{x\sigma\sqrt{2\pi}} \exp(-z^2/2) = \phi(z)/(\sigma\mu) \quad (3.15)$$

mit

$$z = \frac{\log x - \mu}{\sigma} \quad (3.16)$$

Für ihre Verteilungsfunktion und die Momente gilt:

⁴Wenn auch Gewinne aus operationellen Risiken modelliert werden sollen, sollte die Funktion auch allen negativen Zahlen eine Wahrscheinlichkeit zuordnen.

⁵vgl. Klugman u. a. (1998) für Anforderungen an Höhenverteilungen für die Modellierung von Versicherungen

⁶In Basel Committee on Banking Supervision (2004) wird z.B. ein 99.9% Quantil genannt. Für die interne Steuerung sind die Banken frei in Ihrer Entscheidung, welche Quantile sie verwenden. Es können niedrigere, aber auch deutlich höhere sein.

$$F(x) = \Phi(z) \quad (3.17)$$

$$E[X^k] = \exp(k\mu + k^2\sigma^2/2) \quad (3.18)$$

Neben der Lognormalverteilung werden für die Schätzungen ebenfalls die Pareto-, die Weibull- und die Gammaverteilung genutzt.

Die Paretoverteilung hat sehr schwere Ränder. Die Momente existieren lediglich bis zur Ordnung $k < \alpha$, d.h. für $\alpha = 1$ existiert kein Erwartungswert.

Definition 3.6 (Paretoverteilung) Eine Zufallsvariable X ist paretoverteilt mit Parametern θ und α , wenn für ihre Dichtefunktion $f_X(x)_{\theta,\alpha}$ gilt:

$$f_X(x)_{\theta,\alpha} = \frac{\alpha\theta^\alpha}{(x + \theta)^{\alpha+1}} \quad (3.19)$$

Für ihre Verteilungsfunktion und die Momente gilt:

$$F(x) = 1 - \left(\frac{\theta}{x + \theta} \right)^\alpha \quad (3.20)$$

$$E[X^k] = \frac{\theta^k \Gamma(k+1) \Gamma(\alpha - k)}{\Gamma(\alpha)}, \quad -1 < k < \alpha \quad (3.21)$$

Definition 3.7 (Weibullverteilung) Eine Zufallsvariable X ist weibullverteilt mit Parametern θ und τ , wenn für ihre Dichtefunktion $f_X(x)_{\theta,\tau}$ gilt:

$$f_X(x)_{\theta,\tau} = \frac{\tau(x/\theta)^{\tau-1} e^{-(x/\theta)^\tau}}{x} \quad (3.22)$$

Für ihre Verteilungsfunktion und die Momente gilt:

$$F(x) = 1 - e^{-(x/\theta)^\tau} \quad (3.23)$$

$$E[X^k] = \theta^k \Gamma(1 + k/\tau), \quad k > \tau \quad (3.24)$$

Definition 3.8 (Gammaverteilung) Eine Zufallsvariable X ist gammaverteilt mit Parametern θ und α , wenn für ihre Dichtefunktion $f_X(x)_{\theta,\alpha}$ gilt:

$$f_X(x)_{\theta,\alpha} = \frac{(x/\theta)^\alpha e^{-x/\theta}}{x\Gamma(\alpha)} \quad (3.25)$$

Für ihre Verteilungsfunktion und die Momente gilt:

$$F(x) = \Gamma(\alpha; x/\theta) \quad (3.26)$$

$$E[X^k] = \frac{\theta^k \Gamma(\alpha + k)}{\Gamma(\alpha)}, \quad k > -\alpha \quad (3.27)$$

Eine theoretische Begründung die eine Verteilungsfunktion einer anderen vorzuziehen ist bisher für operationelle Risiken nicht bekannt. In Klugman u. a. (1998) finden sich weitere Vorschläge für Verteilungen die für die Modellierung von Verlusthöhen verwendet werden könnten; diese werden nicht weiter berücksichtigt, könnten jedoch durchaus in weiteren Forschungen Verwendung finden.

Zur Schätzung der entsprechenden Parameter können verschiedene Verfahren verwendet werden. Die bekanntesten sind Momentenschätzer und die Maximum-Likelihood-Schätzer. Erläuterungen und Vergleiche der unterschiedlichen Schätzverfahren finden sich in vielen Standardlehrbüchern zur Statistik oder auch in (Klugman u. a. 1998, Seite 45 ff.). In Kapitel 6 werden neben den in Abschnitt 3.4 beschriebenen bayesianischen Ver-

fahren ausschließlich Maximum-Likelihood-Schätzer verwendet, da solche die geringste Varianz aufweisen und sich Maximum-Likelihood-Schätzungen mit angemessenem Aufwand durchführen lassen.

3.3.4. Gesamtverlust

Der Gesamtverlust pro Jahr S entspricht der Summe der Einzelverluste

$$S = \sum_{n=1}^N X_n \quad (3.28)$$

wobei N und X verteilt sind, wie jeweils in Abschnitt 3.3.2 bzw. Abschnitt 3.3.3 beschrieben. Daraus folgt, dass die Verteilung des Gesamtverlustes einer Summe von Faltungen der Einzelverluste entspricht:

$$F_S(x) = \sum_{n=0}^{\infty} p_n F_X^{*n}(x) \quad (3.29)$$

Dabei ist:

$$F_X^{*0}(x) = \begin{cases} 0 & : x < 0 \\ 1 & : x \geq 0 \end{cases} \quad (3.30)$$

und

$$F_X^{*k}(x) = \int_{-\infty}^{\infty} F_X^{*(k-1)}(x-y) f_X(y) dy \quad (3.31)$$

Für die in Kapitel 6 verwendeten Verteilungen, die Poissonverteilung als Häufigkeitsverteilung und die Lognormal-, die Weibull-, die Pareto- und die Gammaverteilung als

Höhenverteilungen, ist diese Gleichung nicht mehr analytisch lösbar, so dass im Weiteren auf eine Monte-Carlo-Simulation zurückgegriffen wird.

3.4. Bayesianische Schätzverfahren

3.4.1. Der Satz von Bayes

Bei der bisherigen Betrachtung wurde ein frequentistischer Ansatz dargestellt. Dabei wird angenommen, dass der datengenerierende Prozess (DGP) existiert und lediglich unbekannt ist. Aufgabe ist es dabei, die Parameter dieses Prozesses zu ermitteln. Dabei soll auf den philosophischen Streit zwischen den beiden Ansätzen (vgl. z.B. Efron (1986); Bayarri und Berger (2004); Iversen (2000); Lavine (2000) und die dort angegebene Literatur) an dieser Stelle nicht eingegangen werden. Beide Ansätze werden pragmatisch gleichberechtigt nebeneinander genutzt.

Bei der Bayes Schätzung wird kein fester zu schätzender Wert der Parameter angenommen; Ziel ist vielmehr die Bestimmung der Verteilung der Parameter bei gegebenen Daten. Die Darstellungsweise folgt erneut (Klugman u. a. 1998, Seite 107 ff.).

Definition 3.9 (A-Priori-Verteilung) *Die A-Priori-Verteilung eines Parameters θ ist eine Wahrscheinlichkeitsverteilung über den Raum aller möglichen Parameter. Sie wird mit $\pi(\theta)$ bezeichnet und repräsentiert unsere A-Priori-Einschätzung bezüglich der Wahrscheinlichkeiten der Ausprägungen des Parameters θ .*

Definition 3.10 (Modellverteilung) *Die Verteilung $f_{X|\Theta}(x|\theta)$ der Zufallsvariablen X unter der Bedingung, dass eine Realisierung θ von Θ gegeben ist, heißt Modellverteilung.*

Definition 3.11 (Gemeinsame Verteilung) Die gemeinsame Verteilung von X und Θ hat die Dichtefunktion $f_{X,\Theta}(x, \theta) = f_{X|\Theta}(x|\theta)\pi(\theta)$.

Definition 3.12 (Randverteilung) Die Randverteilung von x hat die Dichtefunktion $f_X(x) = \int f_{X|\Theta}(x|\theta)\pi(\theta)d\theta$.

Definition 3.13 (A-Posteriori-Verteilung) Die A-Posteriori-Verteilung ist die bedingte Verteilung des Parameters unter der Bedingung der beobachteten Daten. Sie wird mit $\pi_{\Theta|X}(\theta|x)$ bezeichnet.

Definition 3.14 (Prognoseverteilung) Die Prognoseverteilung ist die bedingte Verteilung zukünftiger Realisierungen, falls historische Realisierungen x von X gegeben sind. Sie wird mit $f_{Y|X}(y|x)$ bezeichnet.

Mit Hilfe des Satzes von Bayes können die A-Posteriori-Verteilung und die Prognoseverteilung berechnet werden. Er ist somit die Grundlage aller bayesianischen Berechnungen; der Beweis folgt unmittelbar aus der Definition der bedingten Wahrscheinlichkeit.

Satz 3.3 (Satz von Bayes) Angenommen es wird die Realisierung x einer Zufallsvariable X beobachtet und es sollen Schlüsse über die Realisierung θ einer anderen Zufallsvariable Θ gezogen werden, die mit $\pi(\theta)$ verteilt ist. Dann gilt für die A-Posteriori-Verteilung

$$\pi_{\Theta|X}(\theta|x) = \frac{f_{X|\Theta}(x|\theta)\pi(\theta)}{\int f_{X|\Theta}(x|\theta)\pi(\theta)d\theta} \quad (3.32)$$

Weiterhin gilt für die Prognoseverteilung

$$f_{Y|X}(y|x) = \int f_{Y|\Theta}(y|\theta)\pi_{\Theta|X}(\theta|x)d\theta \quad (3.33)$$

In der Praxis ist die allgemeine Bestimmung dieser Integrale eine schwere Aufgabe, für die es häufig keine analytische Lösung gibt, sondern die z.B. mit Hilfe von Monte-Carlo-Simulation⁷ bestimmt werden muss. Für die bayesianischen Schätzungen im empirischen Teil dieser Arbeit werden daher die A-Priori-Verteilungen jeweils so angenommen, dass die Integrale analytisch lösbar sind. Die folgende Darstellung orientiert sich für die Beschreibung der Bestimmung der Verlusthäufigkeit an (Klugman u. a. 1998, Seite 404) und für die Verlusthöhe an Draper (2005).

3.4.2. Bayesianische Verlusthäufigkeit

Es wird angenommen, dass die Verlusthäufigkeit poissonverteilt mit Häufigkeitsparameter θ ist. Weiterhin sei θ gammaverteilt mit Parametern α und β :

$$\pi(\theta) = \frac{\theta^{\alpha-1} \exp\left(-\frac{\theta}{\beta}\right)}{\Gamma(\alpha)\beta^\alpha} \quad (3.34)$$

Die A-Posteriori-Verteilung ist dann eine Gammaverteilung mit den Parametern

$$\alpha^* = \alpha + n \bar{x} \quad (3.35)$$

$$\beta^* = \frac{\beta}{n\beta + 1} \quad (3.36)$$

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (3.37)$$

und für den Erwartungswert des Parameters θ gilt

$$E(\Theta|x) = \frac{(\alpha + n\bar{x})\beta}{n\beta + 1} \quad (3.38)$$

⁷z.B. mit Hilfe von Gibbs-Sampling

3.4.3. Bayesianische Verlusthöhe

Es wird angenommen, dass die Verlusthöhe Y lognormalverteilt ist. Dann ist $X = \ln(Y)$ normalverteilt. Um die Verteilung von X beschreiben zu können, sind zwei Parameter notwendig $\theta = (\mu, \sigma^2)$. Für deren A-Priori-Verteilung wird angenommen:

$$\sigma^2 \sim \text{SI-}\chi^2(\nu_0, \sigma_0^2) \quad (3.39)$$

$$(\mu|\sigma^2) \sim \text{N}\left(\mu_0, \frac{\sigma^2}{\kappa_0}\right) \quad (3.40)$$

Dabei steht $\text{SI-}\chi^2$ für die skaliert-inverse χ^2 -Verteilung für deren Dichtefunktion gilt:

$$\pi(\sigma^2) = \frac{\left(\frac{1}{2}\nu_0\right)^{\frac{1}{2}\nu_0}}{\Gamma\left(\frac{1}{2}\nu_0\right)} (\sigma_0^2)^{\frac{1}{2}\nu_0} (\sigma^2)^{-(1+\frac{1}{2}\nu_0)} \exp\left(\frac{-\nu_0\sigma_0^2}{2\sigma^2}\right) \quad (3.41)$$

Die Verteilungen wurden so gewählt, dass alle Integrale analytisch gelöst werden können; es ergeben sich die folgenden A-Posteriori-Verteilungen falls $x = (x_1 \dots x_n)$ eine Realisierung der Länge n von X ist (Bernardo und Smith 2000):

$$\sigma^2|x \sim \text{SI-}\chi^2(\nu_n, \sigma_n^2) \quad (3.42)$$

$$\mu|x \sim t_{\nu_n}\left(\mu_n, \frac{\sigma_n^2}{\kappa_n}\right) \quad (3.43)$$

Für die Prognoseverteilung gilt dann:

$$x_{n+1}|x \sim t_{\nu_n}\left(\mu_n, \frac{\kappa_n + 1}{\kappa_n} \sigma_n^2\right) \quad (3.44)$$

mit

$$\nu_n = \nu_0 + n \quad (3.45)$$

$$\sigma_n^2 = \frac{1}{\nu_n} \left(\nu_0 \sigma_0^2 + (n-1)s^2 + \frac{\kappa_0 n}{\kappa_0 + n} (\bar{x} - \mu_0)^2 \right) \quad (3.46)$$

$$\mu_n = \frac{\kappa_0}{\kappa_0 + n} \mu_0 + \frac{n}{\kappa_0 + n} \bar{x} \quad (3.47)$$

$$\kappa_n = \kappa_0 + n \quad (3.48)$$

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (3.49)$$

$$s^2 = \sum_{i=1}^n \frac{(x_i - \bar{x})^2}{n-1} \quad (3.50)$$

Dabei ist $t_\nu(\mu, \sigma^2)$ eine skalierte t -Verteilung für deren Dichtefunktion f gilt, wenn $x \sim t_\nu(\mu, \sigma^2)$

$$f(x) = \frac{\Gamma\left(\frac{1}{2}(\nu+1)\right)}{\Gamma\left(\frac{1}{2}\nu\right) \sqrt{\nu\pi\sigma^2}} \left(1 + \frac{1}{\nu\sigma^2}(x - \mu)^2\right)^{-\frac{1}{2}(\nu+1)} \quad (3.51)$$

Die Nutzung von bayesianischen Verfahren zur Quantifizierung operationeller Risiken wird in der Literatur gelegentlich vorgeschlagen (Alexander 2003b; Giudici und Bilotta 2004). Dabei wird jedoch vielfach nicht berücksichtigt, wie die Genauigkeit und Relevanz der A-Priori-Informationen bezüglich der zu schätzenden Parameter bestimmt werden kann. Wenn die A-Priori-Information für sehr genau gehalten wird, die Parameter jedoch falsch sind, führt die Nutzung zusätzlicher Informationen zu einer schlechteren Parameterbestimmung. Dies wird im empirischen Teil anhand zufälliger Daten nachgewiesen.

3.5. Monte-Carlo-Simulation

Am wesentlichen Prinzip der Monte-Carlo-Simulation (MCS) hat sich seit ihrer Erfindung und ihres erstmaligen Einsatzes von Metropolis (Metropolis u. a. 1953) nichts geändert. Die wichtigsten Vorgehensweisen werden z.B. in Stauffer u. a. (1993) dargestellt. Einen Überblick über weitere Entwicklungen der Monte-Carlo-Simulation findet sich in Dupire (1998).

Gegeben seien Verlustdaten mit der Verlusthöhe, dem Verlustdatum, der Risikokategorie und der Business Line. Eine typische Quantifizierung operationeller Risiken mit Hilfe einer MCS für ein Matrixfeld⁸ der Risikokategorie i und der Business Line j sieht wie folgt aus, wobei hier die Verwendung einer Poissonverteilung für die Häufigkeit und einer Lognormalverteilung für die Verlusthöhe sowie die Unabhängigkeit von Höhen- und Häufigkeitsschätzung unterstellt wird:

1. Parameterbestimmung

- a) Lösche alle Verlustdaten, die nicht sowohl der Kategorie i als auch der Business Line j angehören und die nicht innerhalb des Betrachtungszeitraums liegen.
- b) Schätze die Parameter einer Lognormalverteilung⁹ anhand der jeweiligen Verlusthöhen. In der Schätzung muss berücksichtigt werden, dass ausschließlich Verlustdaten verfügbar sind, die oberhalb eines eventuellen Thresholds liegen. Daher muss die Dichtefunktion noch mit der Verteilungsfunktion an der Stelle des Thresholds skaliert werden¹⁰. Man erhalte die Parameter μ und σ .

⁸In jedem Matrixfeld wird eine Kombination aus Risikokategorie und Business Line berechnet. Basel Committee on Banking Supervision (2004) sieht acht Risikokategorien und sieben Business Lines vor, so dass eine Matrix mit 56 Feldern entsteht.

⁹z.B. mit einer Maximum-Likelihood-Schätzung

¹⁰ $\mathcal{L} = \frac{f(x)}{1-F(\text{Threshold})}$

623. Quantifizierung operationeller Risiken – typische Modellierungsansätze

- c) Schätze die Parameter der Poissonverteilung anhand der Anzahl der Verluste je Zeiteinheit. Dabei ist darauf zu achten, dass dieser Parameter genau wie die Dichtefunktion der Höhenverteilung skaliert werden muss. Man erhalte die Parameter λ .

2. Monte-Carlo-Simulation

- a) Generiere eine poissonverteilte Zufallszahl N mit Parameter λ . Dies entspricht der Anzahl eingetretener Verluste.
- b) Generiere N lognormalverteilte Zufallszahlen mit den Parametern μ und σ . Dies entspricht der jeweiligen Verlusthöhe. Vernachlässige für die folgenden Schritte alle Verluste die unterhalb des Thresholds liegen.
- c) Bilde die Summe der Verlusthöhen. Dies entspricht dem Gesamtverlust im Zeitraum j .
- d) Iteriere J -mal. Erhalte J Realisierungen des Gesamtverlustes.

- 3. Bestimme das gewünschte empirische Quantil aus den J Realisierungen des Gesamtverlustes. Für ein α -Quantil ermittle also den (αJ) -größten Wert. Beachte dabei, dass der simulierte Gesamtverlust auch Einzelverluste beinhalten kann, die unterhalb des Thresholds liegen. Diese werden nicht vernachlässigt, da sie zum Gesamtverlust beitragen und deren Existenz in der Schätzung berücksichtigt worden ist.

4. Güte der Berechnungen

In diesem Kapitel wird die Qualität von VaR- bzw. ES-Messungen analysiert. Dabei sind grundsätzlich die folgenden Fehlerquellen relevant:

1. *Schätzfehler*

Diese resultieren aus der endlichen Länge empirischer Zeitreihen.

2. *Datenfehler*

Diese resultieren aus fehlerhaften Messungen, einer fehlerhaften Aufzeichnung oder Übermittlung.

3. *Modellfehler*

Diese resultieren aus falschen Annahmen bezüglich der Modellierung von Verlustverteilungen oder Prozessen (Jorion 1997, Seite 93).

Im weiteren Verlauf werden wir uns nicht weiter mit der Messung beschäftigen und annehmen, dass diese fehlerfrei durchgeführt wurde. Modellfehler werden erst in Kapitel 6 bei der Durchführung der Simulationen berücksichtigt; in den nächsten Abschnitten werden wir verschiedene Verfahren beschreiben, wie Schätzfehler mit Hilfe von Konfidenzintervallen berücksichtigt werden können.

4.1. Normalverteilte Verluste

Wenn die Verlustverteilung als normalverteilt angenommen werden kann, lassen sich die Konfidenzintervalle in geschlossener Form darstellen. Sei der Gesamtverlust S normalverteilt mit Mittelwert μ und Standardabweichung σ . Dann ist der OpVaR gegeben durch¹:

$$\text{OpVaR} = \Phi_{\mu,\sigma}^{-1}(\alpha) \quad (4.1)$$

$$= \Phi_{0,1}^{-1}(\alpha)\sigma + \mu \quad (4.2)$$

Gegeben sei nun eine Stichprobe vom Umfang n mit Stichprobenvarianz s^2 . Dann folgt die Größe $(n-1)s^2/\sigma^2$ einer χ^2 -Verteilung mit $(n-1)$ Freiheitsgraden:

Wenn man nun den Mittelwert μ der Verlustverteilung zur Vereinfachung als bekannt und gleich Null voraussetzt, folgt für das Konfidenzintervall eines OpVaR zu gegebenem Konfidenzniveau β^2 (Chappell und Dowd 1999):

$$P\left(s\Phi_{0,1}^{-1}(\alpha)\sqrt{\frac{n-1}{\chi_{(n-1),(1-\beta/2)}^2}} \leq \text{OpVaR} \leq s\Phi_{0,1}^{-1}(\alpha)\sqrt{\frac{n-1}{\chi_{(n-1),(\beta/2)}^2}}\right) = \beta \quad (4.3)$$

Dabei ist $\chi_{n,\alpha}^2$ das α -Quantil der χ^2 -Verteilung mit n Freiheitsgraden. Weiterhin gilt für den ES:

¹ $\Phi_{\mu,\sigma}$ ist die Verteilungsfunktion der Normalverteilung mit den Parametern μ und σ und $\Phi_{\mu,\sigma}^{-1}$ deren Umkehrfunktion

²Man beachte den Unterschied zwischen den beiden Niveaus α und β . α ist das Niveau des OpVaR, d.h. die Wahrscheinlichkeit, dass die Verlusthöhe nicht überschritten wird, falls alle relevanten Verteilungsparameter bekannt sind; β bestimmt das Intervall, innerhalb dessen die geschätzten, unbekannten Verteilungsparameter liegen

$$\text{ES} = \int_{\text{OpVaR}}^{\infty} t \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(t-\mu)^2}{\sigma^2}} dt \quad (4.4)$$

Somit ist

$$P \left(\int_{\text{OpVaR}_-}^{\infty} t \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(t-\mu)^2}{\sigma^2}} dt \leq \text{ES} \leq \int_{\text{OpVaR}_+}^{\infty} t \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(t-\mu)^2}{\sigma^2}} dt \right) = \beta \quad (4.5)$$

mit

$$\text{OpVaR}_- = s \Phi_{0,1}^{-1}(\alpha) \sqrt{\frac{n-1}{\chi_{(n-1),(1-\beta/2)}^2}} \quad (4.6)$$

$$\text{OpVaR}_+ = s \Phi_{0,1}^{-1}(\alpha) \sqrt{\frac{n-1}{\chi_{(n-1),(\beta/2)}^2}} \quad (4.7)$$

4.2. Nicht-parametrische Verfahren

Unabhängig von jeder Verteilung gilt aufgrund einfacher statistischer Überlegungen³ für eine geordnete unabhängige Realisierung (iid) $X_{(1)} < X_{(2)} < \dots < X_{(N)}$ der Länge N einer beliebigen Zufallsvariablen X für $r < s$:

$$P(X_r < \xi_\alpha < X_s) = \sum_{i=r}^{s-1} \binom{N}{i} \alpha^i (1-\alpha)^{N-i} \quad (4.8)$$

Diese Gleichung ist universell einsetzbar, solange die Vermutung dass alle Verluste unabhängig und identisch verteilt sind, gültig ist. Allerdings führt sie zu sehr großen Konfidenzintervallen.

³Die Idee beruht im Wesentlichen darauf, dass eine Realisierung einer beliebigen Zufallsvariablen mit einer Wahrscheinlichkeit von α kleiner ist als das entsprechende α -Quantil. (Pritsker 1996; David 1981)

Beispiel 4.1 Nehmen wir an, dass 250 Realisierungen $x_{(1)} \dots x_{(250)}$ einer Zufallsvariablen X als Daten verfügbar seien. Gesucht ist die Wahrscheinlichkeit, dass das 99.9%-Quantil zwischen dem kleinsten x_1 und dem größten x_{250} Messwert liegt. Dann entspricht die Summe

$$\sum_{i=1}^{249} \binom{250}{i} 0.999^i 0.001^{250-i} \quad (4.9)$$

einem Wert von ca. 22.13%. Dabei tragen ausschließlich die letzten vier Summanden ($i = 246 \dots i = 249$) nennenswert zur Summe bei. Somit ist die Wahrscheinlichkeit, dass das 99.9%-Quantil kleiner ist als der größte Messwert kleiner als 25%, so dass dieses Verfahren für die Berechnung von Konfidenzintervallen in der Praxis ungeeignet ist.

4.3. Monte-Carlo-Simulation

Die übliche Behauptung bezüglich der Güte einer Monte-Carlo-Simulation lautet, dass diese mit \sqrt{N} anwächst, wenn N die Anzahl der Simulationsläufe, Iterationen, bezeichnet (siehe z.B. Dowd (1998); Pritsker (1996) u.a.). Dies beruht auf der Erkenntnis, dass mit wachsender Anzahl Iterationen die Fluktuationen innerhalb der MCS abnehmen und die Ergebnisse gegen einen festen Wert konvergieren.

Bei dieser Schlussfolgerung wird jedoch ein wesentlicher Punkt nicht berücksichtigt. Dadurch, dass nur eine endliche Anzahl an Messwerten zur Verfügung steht, gibt es eine natürliche Obergrenze für die Qualität der Schätzungen. Da dieser Fehler immer wieder auftritt, sei er hier an einem einfachen Beispiel erläutert:

Beispiel 4.2 Wir nehmen an, die wahren Verluste aus operationellen Risiken folgen einer Normalverteilung mit Erwartungswert $\mu = 0^4$ und Varianz $\sigma^2 = 1$. Der Erwar-

⁴Dieses Beispiel wurde extrem vereinfacht, damit das dahinter stehende Prinzip besser verdeutlicht

tungswert sei bekannt und ausschließlich die Varianz unbekannt und zu schätzen. Aufgabe ist es nun aus einer Stichprobe den $OpVaR_{0.999}$, den 99.9%-OpVaR zu bestimmen. Der wahre Wert beträgt, wie sich leicht aus den Tabellen für die Standardnormalverteilung ablesen lässt, 3.09.

Die Stichprobe umfasse nun zehn aufgetretene Verluste. Die Stichprobenvarianz betrage $s^2 = 0.7$. Damit ergibt sich mit einer Maximum-Likelihood-Schätzung für den $OpVaR_{0.999}$ ein Wert von $(0.7)(3.09) = 2.16$. Weiterhin ergibt sich aus dem Stichprobenumfang ein 90%-Konfidenzintervall für den geschätzten Wert von:

$$\begin{aligned}
 VaR_{est} \quad \sqrt{\frac{n-1}{\chi^2_{0.95}}} < VaR < VaR_{est} \quad \sqrt{\frac{n-1}{\chi^2_{0.05}}} \\
 (0.7)(3.09) \quad (0.73) < VaR < (0.7)(3.09) \quad (1.65) \\
 1.58 < VaR < 3.57
 \end{aligned} \tag{4.10}$$

Bei einer MCS, die mit den oben beschriebenen Daten und Verfahren durchgeführt würde, würde zunächst der Parameter σ geschätzt, danach Zufallszahlen mit dem geschätzten Parameter gezogen und schließlich wiederum neue Parameter σ geschätzt. Durch ausreichend große Zahl der Iterationen würden die Fluktuationen von σ beliebig klein werden und gegen 2.16 konvergieren. Damit würde eine Scheingenauigkeit vorge-täuscht, da die zunächst ermittelten analytischen Werte aus Gleichung 4.10 sowie der Wert von 3.06 für den $OpVaR_{0.999}$ weiterhin gültig bleiben.

werden kann. Es können negative Verluste = Gewinne aus operationellen Risiken mit einer Wahr-scheinlichkeit von 50% auftreten. Dies ist in der Realität mit Sicherheit nicht der Fall.

Teil II.

Simulation

5. Entwicklung eines neuen Verfahrens für die Monte-Carlo- Simulation – der „doppelten Monte-Carlo-Simulation“

The reason for setting up H_0 is not to describe the Ultimate Realities of the Universe; that is unknown and remains so. By definition, the function of H_0 is to represent what we know; it cannot be unknown. So a second attitude recommends itself; define your H_0 as best you can – all the diseases you know – and get on with the calculations.

E.T. Jaynes (Jaynes 1984)

Die Güte der durchgeführten Schätzungen wird in der bisher verfügbaren Literatur zum Thema „operationelle Risiken“ nicht ausreichend hinterfragt. Vermutlich sind sich alle Autoren bewusst, dass zu Beginn der Entwicklung der Modellierung einer Risikoart, wie in diesem Fall operationeller Risiken, die Ergebnisse qualitativ deutlich hinter denen bereits etablierter Modelle bei Kredit- oder Marktrisiken zurückbleiben müssen. Dennoch macht es Sinn und ist notwendig, bereits in diesem frühen Stadium mit ei-

ner Qualitätsmessung zu beginnen, denn nur, wenn die Qualität der Modelle bekannt ist, können Modelle miteinander verglichen und bessere von schlechteren Vorhersagen unterschieden werden.

Nachdem daher in den vorangegangenen Kapiteln zunächst der fachliche und technische Hintergrund sowie bereits bekannte Verfahren zur Quantifizierung operationeller Risiken dargestellt wurden, soll in diesem Kapitel ein Modell vorgestellt werden, dass es erlaubt, die mögliche Genauigkeit von Quantifizierungsmodellen zu bestimmen. Unter der Voraussetzung, der tatsächliche datengenerierende Prozess (DGP) sei bekannt, wird die Güte der folgenden Schätzungen ermittelt, indem die bekannten tatsächlichen Ergebnisse mit den Schätzergebnissen verglichen werden. In Kapitel 6 werden diese theoretischen Überlegungen dann umgesetzt, indem das vorgestellte Modell mit verschiedenen Parametern berechnet wird und die Ergebnisse dargestellt und analysiert werden.

Um die gewünschten Ergebnisse zu erhalten, wird ein neues Verfahren entwickelt. Dieses basiert auf der beschriebenen Methode der Monte-Carlo-Simulation und erlaubt die Berechnungen von Konfidenzintervallen für die gewünschten OpVaR- und ES-Werte, d.h mit Hilfe der beschriebenen Methode kann ermittelt werden, innerhalb welchen Bereichs der geschätzte Wert vermutlich schwanken wird, unter der Bedingung, dass der tatsächliche OpVaR bzw. ES einen bestimmten Wert annimmt. Dazu werden zwei ineinander verschachtelte MCS durchgeführt, wobei der Schritt 3 dem in Abschnitt 3.5 beschriebenen Verfahren entspricht.

Prinzipielle Annahme des vorgestellten Verfahrens ist, dass ein datengenerierender Prozess (DGP) für die Generierung der Verlustdaten existiert. Dieser wird mit $\mathcal{M}_{real}(\Theta)$ bezeichnet. Dabei sei Θ der Vektor der dem Prozess zugrunde liegenden Parameter. Das Risiko soll mit Hilfe des OpVaR gemessen werden¹.

¹Für die Messung des ES oder ggf. anderer Kennzahlen lassen sich die Anweisungen einfach übertragen.

Beispiel 5.1 Sei zum Beispiel $\mathcal{M}_{real}(\Theta)$ wie folgt definiert:

Das kollektive Modell ist gültig und somit die Höhe und Häufigkeit von Verlusten voneinander unabhängig. Die Häufigkeitsverteilung ist eine Poissonverteilung mit dem Parameter $\theta_1 = \lambda = 5$ und die Höhenverteilung eine Lognormalverteilung mit den Parametern $\theta_2 = \mu = 8.33$ und $\theta_3 = \sigma = 1.78$, so dass für einen einzelnen Verlust der Erwartungswert 20.000 und das 99.9%-Quantil 1.000.000 beträgt.

Ziel ist es nun zu ermitteln, ob die Parameter dieses Modells nun mit Hilfe von Schätzungen reproduziert werden können und welche Schwankungen zu erwarten sind. Dazu wird vorgeschlagen, wie folgt vorzugehen:

1. Annahmen

- a) Annahme der Ausprägung des Modells inklusive aller Parameter².
- b) Annahme der Länge der Zeitreihe T ³.
- c) Annahme des Schätzmodells \mathcal{M}_{est} und des dazugehörenden Schätzverfahrens \mathcal{V}_{est} ⁴.

2. Generierung der Verlustdaten. Diese stellen die Datenbasis für die empirischen Schätzungen dar. Im Gegensatz zu einer realen Datenbasis besteht hier der Vorteil, dass der zugrunde liegende DGP vollständig bekannt ist.

- a) T -maliges Ziehen der Werte $N_t | t = 1 \dots T$ aus der Häufigkeitsverteilung.
- b) Jeweils N_t -maliges Ziehen aus der Höhenverteilung für alle $t = 1 \dots T$ und Erhalt von $\sum_{t=1}^T N_t$ Verlustdaten.

²Dies könnte z.B. das Modell aus Beispiel 5.1 sein.

³Dies entspricht der Datenhistorie, die für Schätzungen zur Verfügung stehen soll

⁴Zum Beispiel sei das Schätzmodell gleich dem wahren Modell und sei das Schätzverfahren eine Momentenschätzung für die Verlusthäufigkeit und eine Maximum-Likelihood-Schätzung für die Verlusthöhe.

Die hier generierten Daten⁵ sind im Folgenden der ausschließliche Zugang zu dem DGP. Das Modell selbst wird für die weiteren Schätzungen nicht mehr verwendet⁶

3. Bestimmung des OpVaR mit Hilfe des Schätzverfahrens \mathcal{V}_{est} anhand der generierten Verlustdaten. Das Ergebnis sei OpVaR_i . Hier kann z.B. die MCS aus Abschnitt 3.5 verwendet werden.
4. Iteration der Schritte zur Generierung von Verlustdaten und zum Schätzprozess jeweils $i = 1 \dots I$ -mal. Erhalt von I Realisierungen möglicher OpVaRs
5. Bestimmung der Verteilung und insbesondere der gewünschten empirischen Quantile des OpVaR⁷. Diese Quantile geben an, in welchem Bereich sich ein empirisch geschätztes OpVaR befinden wird, unter der Bedingung dass der tatsächliche DGP dem zu Beginn angenommenen entspricht.

Das beschriebene Verfahren der doppelten Monte-Carlo-Simulation (dMCS) wird nun in Kapitel 6 auf verschiedene Modelltypen mit jeweils unterschiedlichen Parametern angewendet. Ziel ist die Bestimmung von Konfidenzintervallen für das OpVaR. Für jede Parameterkombination wird zunächst sich das aus den Modellannahmen ergebende wahre 99.9%-Quantil mit Hilfe einer Monte-Carlo-Simulation bestimmt. Dann werden, wie oben beschrieben, jeweils das empirische 5%-Quantil und das empirische 95%-Quantil mit Hilfe unterschiedlicher Schätzmodelle bzw. -verfahren bestimmt und diese Werte dann mit dem wahren OpVaR verglichen.

⁵Implizit wurde bei der Generierung der Daten vorausgesetzt, dass der versicherungstechnische Ansatz gültig ist. Sollte dies im DGP nicht der Fall sein ist der Vorgang entsprechend anzupassen.

⁶Zur Vereinfachung wird für die Schätzungen ein Modell verwendet, dass dem tatsächlichen Modell sehr ähnlich ist. Dies wird umgesetzt, um zu zeigen, wie gut eine Schätzung maximal werden kann, wenn relativ wenige Fehlerquellen bestehen. Für weitere Forschungen ist es ohne weiteres möglich, Modelle zu schätzen, die vom DGP beliebig weit entfernt sind. Vermutlich werden die Ergebnisse der Schätzungen dann ebenfalls von der Realität beliebig weit entfernt sein.

⁷Z.B. kann ein empirisches 90%-Konfidenzintervall dadurch bestimmt werden, dass der Wert der von 5% der OpVaR unterschritten wird, als Untergrenze und der Wert der von 5% der OpVaR überschritten wird als Obergrenze verwendet wird.

6. Simulationsergebnisse

Ziel dieses Kapitels und damit dieser Arbeit ist es, die Güte einfacher Modelle zur Quantifizierung operationeller Risiken mit Hilfe der in Kapitel 5 vorgestellten Methode der doppelten Monte-Carlo-Simulation (dMCS) zu bestimmen. Dazu werden Konfidenzintervalle bestimmt, die bei optimaler Qualität der Daten und wenn das den Verlusten tatsächlich zugrunde liegende Modell in wesentlichen Teilen bekannt ist, mindestens noch aufgrund der geringen Anzahl der Daten verbleiben müssen. Wenn entweder die Qualität nicht optimal ist wie hier angenommen oder zusätzliche Modellunsicherheiten zu berücksichtigen sind, werden die Intervalle vermutlich deutlich größer werden. Eine Bank sollte daher als Sicherheit nicht die durch eine Simulation ermittelten Werte als Kapital vorhalten, sondern die Obergrenze dieser Konfidenzintervalle, um so die Wahrscheinlichkeit zu vergrößern, mindestens so viel Kapital zu besitzen, wie dem geforderten 99.9%-Quantil entspricht.

In diesem Kapitel wird das in Abschnitt 3.3 beschriebene versicherungstheoretische Modell in Hinblick auf die Güte der Schätzung in Abhängigkeit von den tatsächlichen Häufigkeits- und Höhenparametern des DGP untersucht. Dabei werden unterschiedliche Modelltypen untersucht. In Abschnitt 6.3 wird für die Schätzung der Höhe ein Maximum-Likelihood-Ansatz gewählt. Da dabei ein Threshold für die Verlustdatensammlung angenommen wird, ist eine numerische Optimierung erforderlich. In Abschnitt 6.4 wird

die Verlusthöhe mit Hilfe des in Abschnitt 3.4 vorgestellten bayesianischen Ansatzes geschätzt. Als A-Priori-Information werden geschätzte Parameter in verschiedenen Ausprägungen genutzt¹. Dort wird auf die Nutzung eines Thresholds verzichtet, so dass die Schätzungen analytisch durchgeführt werden können.

Für die Schätzung der Verlusthäufigkeit wird jeweils eine Poissonverteilung angenommen, deren Parameter λ mit Hilfe eines Momentenschätzers bestimmt wird. Aufgrund der geringen Anzahl erwarteter Verlustdaten ist es möglich, dass eine Schätzung der Höhenparameter nicht durchgeführt werden kann. Daher wird keine Schätzung durchgeführt, wenn in der 5-jährigen Historie insgesamt weniger als 5 Verlustereignisse aufgetreten sind.

6.1. Annahmen

Für die weiteren Berechnungen wird vorausgesetzt, dass alle in Abschnitt 2.4 die Qualität betreffenden Probleme gelöst sind und als einzige Quelle der Unsicherheit bei Verlustdaten deren beschränkte Anzahl verbleibt. Ziel soll die Ermittlung von Konfidenzintervallen des zu berechnenden 99.9%-OpVaR bzw. des zu diesem gehörenden ES in Abhängigkeit der tatsächlichen Parameter der Verlustverteilungen sein. Zur Bestimmung dieser Quantile wird die in Abschnitt 4.3 beschriebene Methode verwendet. Alle Beträge in diesem Kapitel sind grundsätzlich Eurowerte, um eine Konsistenz zu Basel II (Basel Committee on Banking Supervision 2004), in dem ein Threshold von 10.000 EUR vorgeschlagen wird, zu erhalten.

Die hier verwendeten Annahmen sind sehr restriktiv. In späteren Forschungen könnten die hier genannten Annahmen dann nach und nach gelockert werden.

¹z.B. mit Hilfe einer Szenarioanalyse oder eines Self-Assessments

1. Optimaler Datensammlungsprozess

Für den Prozess der Datensammlung wird angenommen, dass alle relevanten Verluste aus operationellen Risiken

- a) perfekt gegenüber anderen Risikoarten abgegrenzt sind
- b) korrekt der entsprechenden Business Line zugeordnet wurden
- c) in die richtige Risikokategorie einsortiert wurden
- d) aus einem einzelnen Ereignis resultieren, welches direkt zum Eintritt des Schadens geführt hat
- e) dem Datum nach eindeutig sind
- f) der Höhe nach eindeutig sind
- g) alle in der gleichen Währung verfügbar sind
- h) passend abgezinst worden sind
- i) sofort verbucht wurden
- j) in die Datenbank eingetragen wurden
- k) Daten aus unterschiedlichen Datenquellen angemessen verknüpft (z.B. mit der „Credibility Theory“ Bühlmann und Straub (1970); Longley-Cook (1962); Norberg) und skaliert (Baud u. a. 2002; Frachot und Roncalli 2002) wurden

2. bekannte Umwelt

Der Prozess der zum Entstehen von Verlusten führt, ist im Wesentlichen bekannt und entspricht dem in Abschnitt 3.3 beschriebenen versicherungstheoretischen Modell.

3. statische Umwelt

Die Verteilungen für die Verlusthöhe und – je nach Modell – auch für die Verlusthäufigkeit haben feste Parameter, die nicht zeitlich veränderlich sind.

6.2. Technische Informationen

Die Simulationen wurden in FORTRAN90 programmiert. Diese Sprache hat den Vorteil, dass sie einerseits einfach umzusetzen ist und hochgradig auf numerische Operationen hin optimiert werden kann. Für die numerische Optimierung wurde die IMSL Bibliothek in Fortran genutzt. Die Berechnungen wurden auf einem Pentium Mobile 1.5 Ghz mit dem Betriebssystem Windows XP durchgeführt. Der Speicher war kein Engpasskriterium, da nicht alle Zwischenergebnisse sondern ausschließlich der OpVaR bzw. der ES zwischengespeichert wurden. Maximal wurde vom Programm eine Speichermenge von 50MB genutzt. Die vorgeschaltete MCS mit 1.000.000 Iterationen nahm ca. fünf Minuten in Anspruch; die Ermittlung der Konfidenzintervalle für den OpVaR und den ES dauerte für den in Abschnitt 6.3 durchschnittlich zwei Stunden je Parameterkombination². Im Abschnitt 6.4 war keine numerische Optimierung mehr notwendig, da auf den Threshold verzichtet wurde und der Maximum-Likelihood-Schätzer stets analytisch ermittelt werden konnte. Daher war die Ermittlung des OpVaR in ca. 20 Minuten je Modell möglich³.

²Somit betrug die Gesamtdauer für einen Modelltyp ca. 50 Stunden und die Berechnung aller Modelle in Abschnitt 6.3 250 Stunden.

³Die Gesamtdauer für einen Modelltyp betrug daher 3 Stunden und für den Abschnitt 6.4 6 Stunden.

6.3. Modelle ohne Berücksichtigung von A-Priori-Informationen

In diesem Abschnitt werden die Ergebnisse fünf unterschiedlicher Modelle dargestellt. Die Häufigkeitsschätzung beruht in allen Fällen auf der Poissonverteilung; die Höhengschätzung wird immer unter der Annahme einer Lognormalverteilung durchgeführt. Die Unterschiede zwischen den Modellen bestehen im DGP. Die Verlusthäufigkeit folgt für alle Modelle einer Poissonverteilung. Im Abschnitt 6.3.1 folgt die Höhenverteilung in Übereinstimmung mit der Schätzung einer Lognormalverteilung. In den folgenden Abschnitten 6.3.2, 6.3.3, 6.3.4 und 6.3.5 folgt die Höhenverteilung jeweils der Pareto-, der Weibull- oder der Gammaverteilung oder die zugrunde liegende Verteilung wird zufällig mit jeweils gleicher Wahrscheinlichkeit aus den vier verschiedenen Verteilungen gezogen. Mit der Variation der Verteilungen soll untersucht werden, wie sich Fehler in der Verteilungsannahme auf die Güte der Schätzungen auswirken.

Zu jedem der fünf Modelle werden 24 Simulationen mit verschiedenen Parametern durchgeführt. Dabei nimmt der Parameter λ der Poissonverteilung, der die erwartete Anzahl Verlust je Zeiteinheit angibt⁴, die Werte 5, 10, 25, 50, 100 und 250 an. Die Parameter der Höhenverteilung werden ermittelt, indem jeweils der Erwartungswert und das 99.9%-Quantil eines einzelnen Verlustes vorgegeben werden. Sollte die Bestimmung nicht eindeutig sein, wird die Parameterkombination verwendet, die einen größeren Anteil der Wahrscheinlichkeitsmasse oberhalb des Thresholds hat. Das 99.9%-Quantil des einzelnen Verlustes wird bei 1.000.000 festgehalten, die Erwartungswerte können die Werte 20.000, 30.000, 40.000 und 50.000 annehmen. Aus der Kombination mit den Häufigkeit-

⁴Dies gibt die erwartete Anzahl aller Verluste an, um die Anzahl der Verluste oberhalb des Thresholds zu erhalten muss noch mit dem Anteil der Verlusthöhenverteilung oberhalb des Thresholds skaliert werden.

sparametern ergeben sich dann die 24 Simulationsdurchläufe.

Für die Verlustdatensammlung wird in Übereinstimmung mit den Vorschlägen aus Basel Committee on Banking Supervision (2004) ein Threshold von 10.000 festgelegt. Verlusthöhen, die kleiner sind als dieser Threshold, werden nicht für die Schätzungen verwendet. Die Festlegung der Zeiteinheit auf ein Jahr ist willkürlich gewählt. Ein größeres λ könnte auch bedeuten, dass über einen längeren Zeitraum bei gleichem λ gemessen wurde. Bei den Histogrammen wurde eine logarithmische Skalierung gewählt, da die Schwankungen sehr stark sind und ansonsten keine anschauliche Darstellung möglich gewesen wäre.

Als Ergebnisse der jeweiligen Schätzungen werden nicht nur der von der Bankenaufsicht vorgegebene $\text{OpVaR}_{0,999}$ sondern auch der $\text{ES}_{0,999}$ ermittelt.

6.3.1. Modell Lognormal–Lognormal

Im Modell Lognormal–Lognormal (Log–Log) stimmen die Verlusthöhenverteilung des DGP und diejenige des Schätzmodells überein. Unbekannt sind ausschließlich die entsprechenden Verteilungsparameter. Die Häufigkeit folgt einer Poissonverteilung mit dem Parameter λ und die Verlusthöhe folgt einer Lognormalverteilung mit den Parametern μ und σ . Weiterhin wird davon ausgegangen dass eine 5-jährige Datenhistorie vorliegt, der von der Aufsicht nach der Übergangsphase als Minimum vorgesehene Wert.

Die verschiedenen verwendeten Spezifikationen sind in Tabelle 6.1 dargestellt, die daraus resultierenden Parameter der Höhenverteilung finden sich in Tabelle 6.2. Es sind zwei Häufigkeitsparameter relevant. Zunächst der wahre Parameter, der Werte von 5 bis 250 annehmen kann. Dieser kann jedoch nicht direkt gemessen werden, da Verluste unterhalb des Thresholds nicht berichtet werden. Daher gibt es zusätzlich noch den gemessenen Parameter mit Werten von 1.5 bis 192.2. Dieser ist ebenfalls in der Tabelle dargestellt.

Modell			A	B	C	D
	lambda	Erwartungswert	20,000	30,000	40,000	50,000
		99.9%-Quantil	1,000,000	1,000,000	1,000,000	1,000,000
		Anteil Datenverlust durch Threshold	69%	51%	35%	23%
1	5		1.5	2.5	3.2	3.8
2	10		3.1	4.9	6.5	7.7
3	25		7.7	12.3	16.2	19.2
4	50		15.5	24.7	32.4	38.4
5	100		30.9	49.4	64.9	76.9
6	250		77.3	123.5	162.2	192.2

Tabelle 6.1.: Kurzdarstellung der Modellspezifikation des Modells Log-Log. Mit den Spalten variiert der Erwartungswert eines einzelnen Verlustes (Parameterausprägung Höhe A–D); mit den Zeilen variiert der Häufigkeitsparameter λ (Parameterausprägung Häufigkeit 1–6). Aus der Kombination ergeben sich die simulierten Parameterausprägungen (A1–D6). Dargestellt ist der tatsächliche Erwartungswert für die Verlustanzahl eines einzelnen Jahres nach Berücksichtigung des Thresholds von 10.000.

Modell		A	B	C	D
Lognormal	μ	8.33 E+0	8.19 E+0	9.71 E+0	1.01 E+1
	σ	1.78 E+0	1.50 E+0	1.33 E+0	1.20 E+0

Tabelle 6.2.: Darstellung der berechneten Werte für die Parameter der Höhenverteilung. Der Erwartungswert entspricht jeweils dem in Tabelle 6.1 dargestellten Betrag von 20.000–50.000. Das 99.9%-Quantil eines einzelnen Verlustes ist 1.000.000. Daraus werden die hier angegebenen Parameter berechnet. Falls aufgrund dieser Vorgaben noch keine eindeutige Ermittlung der Parameter möglich ist, wird die Parameterkombination verwendet, die den Anteil der Verluste oberhalb des Thresholds maximiert.

Das Verhältnis zwischen beiden entspricht dem Anteil der Höhenverteilung oberhalb des Thresholds. Da von einer 5-jährigen Historie ausgegangen wird, steht im Mittel auch das 5-fache dieser Anzahl an Verlusten für die Höhenschätzungen zur Verfügung.

In einem ersten Schritt werden die tatsächliche Höhe des $\text{OpVaR}_{0.999}$ und des dazu gehörenden ES der Gesamtverlustverteilung bestimmt. Dazu wird eine Monte-Carlo-Simulation mit den angenommen Parametern durchgeführt. Dies sei hier beispielhaft an




Abbildung 6.1.: In dieser Abbildung wird die MCS zur Ermittlung des tatsächlichen OpVaR beispielhaft für die Parameterausprägung A1 des Modells Log-Log dargestellt. Es zeigt sich, dass nach ungefähr 200.000 Iterationen die MCS bereits ausreichend stabil wird. Eine Darstellung der MCS für die übrigen Parameterausprägungen findet sich im Anhang.

Parameterausprägung A1⁵ für den OpVaR gezeigt und ist in Abbildung 6.1 dargestellt. Mit Hilfe dieser Grafik kann zusätzlich überprüft werden, wie viele Iterationen notwendig sind, damit die Fluktuationen innerhalb der MCS ausreichend klein sind⁶. Es wurden 1.000.000 Iterationen durchgeführt, aus der Grafik ist ersichtlich, dass auch ca. 200.000 Iterationen ausreichen, um eine angemessene Genauigkeit zu erzielen. Bei der gewählten Anzahl an Iterationen ist aus Performancegründen darauf zu achten, dass nicht zu viele durchgeführt werden, da die Simulation selbst sehr häufig durchgeführt werden muss

⁵Die zu den jeweiligen Parameterausprägungen gehörenden Parameter lassen sich den Tabellen entnehmen. Z.B. sind die Verteilungsparameter für die Parameterausprägung Höhe „A“ $\mu = 8.33$ und $\sigma = 1.78$; die Parameterausprägung Häufigkeit „1“ zeigt einen Häufigkeitsparameter von $\lambda = 5$ ohne Berücksichtigung des Thresholds an.

⁶Die fälschliche Erhöhung der „Güte“ wie in Abschnitt 4.3 beschrieben.




Abbildung 6.2.: In dieser Abbildung wird die MCS zur Ermittlung des tatsächlichen ES beispielhaft für die Parameterausprägung A1 des Modells Log-Log dargestellt. Bereits nach 400.000 Iterationen ist die Simulation ausreichend stabil.

und daher diese Anzahl großen Einfluss auf die Gesamtperformance hat. Weiterhin ist die Genauigkeit einer einzelnen Iteration auch nicht entscheidend für das Endergebnis, da hier über die 500 durchgeführten MCS die Konfidenzintervalle bestimmt werden und sich Fluktuationen daher zusätzlich herausmitteln. Andererseits kann nicht jede Durchführung manuell überprüft werden und die Parameter können insbesondere bei kleineren Häufigkeitsparametern stark voneinander abweichen, so dass auch die Fluktuationen erst bei einer größeren Iterationszahl verschwinden. Daher sollte ein angemessener Kompromiss gefunden werden und es werden jeweils 500.000 Iterationen durchgeführt.

Die tatsächlichen Werte für den OpVaR und den ES für alle Parameterkombinationen sind in Tabelle 6.3 sowie Tabelle 6.4 dargestellt. Die entsprechenden Grafiken finden sich im Anhang.

Modell	A	B	C	D
1	2.4	2.2	2.1	2.0
2	3.3	2.9	2.8	2.8
3	5.1	4.3	4.2	4.3
4	7.1	6.3	6.1	6.3
5	10.2	9.0	9.2	9.8
6	16.8	15.9	17.1	19.2

Tabelle 6.3.: Übersicht über die tatsächliche Höhe des OpVaR für das Modell Log–Log für alle Parameterausprägungen jeweils in Millionen. Die Ergebnisse wurden mit einer MCS mit 1.000.000 Iterationen gewonnen.

Modell	A	B	C	D
1	4.0	3.4	2.9	2.7
2	5.4	4.3	3.8	3.6
3	8.2	6.2	5.4	5.3
4	10.9	8.5	7.6	7.4
5	14.9	11.7	11.0	11.1
6	22.8	19.0	19.1	20.7

Tabelle 6.4.: Übersicht über die tatsächliche Höhe des ES für das Modell Log–Log für alle Parameterausprägungen jeweils in Millionen. Die Ergebnisse wurden mit einer MCS mit 1.000.000 Iterationen gewonnen.

Im nächsten Schritt wird die MCS wie in Kapitel 5 beschrieben durchgeführt. Es werden aus den wahren Verlustverteilungen Pseudoverluste generiert und diese mit dem angegebenen Modell geschätzt. Dabei werden in der inneren MCS 500.000 Iterationen verwendet. Aufgrund der Übereinstimmung der Modelle und da die verwendeten Schätzverfahren keine Verzerrung aufweisen, kann so eine beliebige Genauigkeit der Schätzungen erreicht werden. Da es an dieser Stelle das Ziel ist zu zeigen, wie die Modelle sich bei wenigen verfügbaren Daten verhalten, wird lediglich eine geringe Anzahl Verluste generiert, d.h. in diesem Fall, dass die Datenhistorie auf fünf Jahre beschränkt wird. Dieses Vorgehen wird 500-mal wiederholt, bis ein aussagekräftiges Histogramm entsteht. Für die Parameterausprägung A1 ist dieses in Abbildung 6.3 für den OpVaR und in Ab-




Abbildung 6.3.: Diese Grafik zeigt die Schwankungen des geschätzten OpVaR für das Modell Log-Log mit Parameterausprägung A1. Die Höhenverteilung des DGP folgt einer Lognormalverteilung mit den Parametern $\mu = 8.33$ und $\sigma = 1.78$. Die Häufigkeitsverteilung folgt eine Poissonverteilung mit dem Parameter $\lambda = 5$. Der tatsächliche OpVaR für diese Parameterausprägung beträgt ca. 2 Mio. Für die Schätzung wird als Höhenverteilung ebenfalls die Lognormalverteilung angenommen und als Häufigkeitsverteilung ebenfalls die Poissonverteilung. Es ist ersichtlich, dass der geschätzte OpVaR in vielen Fällen in der Nähe des tatsächlichen Wertes liegt; es gibt jedoch große Abweichungen sowohl nach unten als auch nach oben. In 95% der Fälle liegt der Wert über 0.15 Mio; in 95% der Fälle liegt er unter 15.7 Mio. Dies entspricht Schwankungen von 93% nach unten und 566% nach oben.

bildung 6.4 für den ES dargestellt. Die Größenklassen des Histogramms wachsen dabei exponentiell an, damit die großen Schwankungen angemessen dargestellt werden können.

Dieses Verfahren wurde mit allen dargestellten Parameterausprägungen durchgeführt. Die berechneten Konfidenzintervalle sind abschließend für alle Parameterausprägungen in Tabelle 6.5 für den VaR sowie in Tabelle 6.6 für den ES gezeigt⁷. Es zeigt sich,

⁷In diesem Kapitel werden die Ergebnisse zusammenfassend dargestellt. Alle Grafiken und Histogram-




Abbildung 6.4.: Diese Grafik zeigt die Schwankungen des geschätzten ES für das Modell Log-Log mit Parameterausprägung A1. Die Höhenverteilung des DGP folgt einer Poissonverteilung mit den Parametern $\mu = 8.33$ und $\sigma = 1.78$. Die Häufigkeitsverteilung folgt einer Poissonverteilung mit dem Parameter $\lambda = 5$. Der tatsächliche ES für diese Parameterausprägung beträgt ca. 4 Mio. Für die Schätzung wird als Höhenverteilung ebenfalls die Lognormalverteilung angenommen und als Häufigkeitsverteilung ebenfalls die Poissonverteilung. Es ist ersichtlich, dass der geschätzte ES in vielen Fällen in der Nähe des tatsächliche Wertes liegt; es gibt jedoch große Abweichungen sowohl nach unten als auch nach oben. In 95% der Fälle liegt der Wert über 0.18 Mio; in 95% der Fälle liegt er unter 48.4 Mio. Dies entspricht Schwankungen von 95% nach unten und 1125% nach oben.

dass, selbst wenn das Modell bekannt ist und abgesehen von den Verteilungsparametern keinerlei Unsicherheiten vorliegen, bei einer erwarteten Verlustanzahl von 50 Verlusten im Jahr und 5 Jahren Historie, d.h. einer erwarteten Verfügbarkeit von 250 Daten, die Schwankungen des OpVaR noch bei allen Parameterausprägungen Höhe A–D über 50% betragen. Selbst die geringsten Schwankungen betragen noch mehr als 15%.

me sind in Anhang 7 vollständig aufgeführt.

Modell		A		B		C		D	
	Quantil	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler
1	5%	157,265	93%	290,778	87%	412,629	80%	563,577	72%
	95%	15,670,006	566%	13,508,683	524%	12,601,149	506%	8,710,710	334%
2	5%	337,305	90%	606,242	79%	877,561	68%	1,092,125	60%
	95%	28,957,436	778%	24,650,012	754%	10,900,777	292%	8,222,833	198%
3	5%	983,174	81%	1,667,341	62%	2,153,160	49%	2,477,518	42%
	95%	26,222,045	410%	21,557,338	396%	11,626,534	176%	7,963,684	86%
4	5%	2,323,502	67%	3,164,347	49%	3,843,907	37%	4,423,339	30%
	95%	39,089,889	447%	13,560,594	116%	11,208,068	85%	9,990,079	58%
5	5%	4,271,842	58%	5,370,308	41%	6,679,512	28%	7,938,990	19%
	95%	36,624,385	260%	18,684,078	107%	12,967,831	40%	13,379,782	36%
6	5%	9,824,910	42%	11,929,889	25%	14,401,306	16%	17,031,779	11%
	95%	33,947,318	102%	22,252,593	40%	20,762,961	21%	22,211,164	16%

Tabelle 6.5.: Übersicht über die Konfidenzintervalle und die relativen Fehler für den OpVaR für alle Parameterausprägungen für das Modell Log-Log. Die tatsächlichen OpVaR sind in Tabelle 6.3 dargestellt. Es zeigt sich, dass bei einer erwarteten Verlustanzahl von 50 Verlusten pro Jahr und 5 Jahren Historie, also bei einer erwarteten Verfügbarkeit von 250 Datenpunkten, die Schwankungen nach oben noch für alle Parameterausprägungen für die Höhe A–D über 50% betragen. Selbst die geringsten Schwankungen nach oben bei einer erwarteten Verfügbarkeit von 1.250 Datenpunkten betragen noch mehr als 15%.

Modell		A		B		C		D	
	Quantil	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler
1	5%	178,852	95%	327,720	90%	480,678	83%	653,890	76%
	95%	48,447,475	1125%	35,261,881	950%	27,571,060	856%	15,290,471	468%
2	5%	381,952	93%	691,666	84%	1,018,984	73%	1,224,346	66%
	95%	86,555,455	1513%	60,896,492	1325%	18,749,790	389%	12,842,291	260%
3	5%	1,171,109	86%	1,967,135	68%	2,529,886	54%	2,795,704	47%
	95%	67,743,063	724%	45,692,076	637%	18,675,368	243%	10,881,190	107%
4	5%	2,832,274	74%	3,691,623	57%	4,359,578	42%	4,872,803	34%
	95%	95,039,080	769%	21,552,739	154%	16,040,468	112%	12,845,332	73%
5	5%	5,145,283	66%	6,245,114	46%	7,492,867	32%	8,686,505	22%
	95%	73,319,329	391%	27,635,581	137%	16,561,796	50%	16,139,444	46%
6	5%	12,218,481	46%	13,570,116	29%	15,579,896	19%	18,009,796	13%
	95%	54,379,623	139%	29,251,530	54%	24,611,867	29%	24,224,767	17%

Tabelle 6.6.: Übersicht über die Konfidenzintervalle und die relativen Fehler für den ES für alle Parameterausprägungen für das Modell Log-Log. Die tatsächlichen ES sind in Tabelle 6.4 dargestellt. Es zeigt sich, dass bei einer erwarteten Verlustanzahl von 50 Verlusten pro Jahr und 5 Jahren Historie, also bei einer erwarteten Verfügbarkeit von 250 Datenpunkten, die Schwankungen noch für alle Parameterausprägungen für die Höhe A–D über 70% betragen. Selbst die geringsten Schwankungen nach oben bei einer erwarteten Verfügbarkeit von 1.250 Datenpunkten betragen noch mehr als 15%.

6.3.2. Modell Lognormal–Pareto

Das Modell Lognormal–Pareto (Log–Par) entspricht im Wesentlichen dem im vorherigen Abschnitt beschriebenen Modell Log–Log. Der Unterschied zum Modell Log–Log besteht darin, dass die Verlusthöhenverteilung des DGP keine Lognormalverteilung mehr ist, sondern eine Paretoverteilung. Dadurch wird eine zusätzliche Unsicherheit eingeführt, mit deren Hilfe überprüft werden soll, wie sensibel die Schätzungen auf Veränderungen des Modells reagieren.

Im Vergleich zum Modell Log–Log ist in Tabelle 6.7 ersichtlich, dass Aufgrund der Änderung der Verteilung des DGP der Anteil nicht in die Verlustdatenbank aufgenommener Verluste für die Parameterausprägungen A, B und C leicht sinkt und für die Parameterausprägung D leicht von 23% auf 26% steigt. Somit sind in diesem Fall anstelle von 192.2 Fällen pro Jahr nur noch 185.4 Fälle zu erwarten, die den Threshold übersteigen.

Bei der Ermittlung des tatsächlichen OpVaR bzw. ES zeigt sich in den Abbildun-

Modell			A	B	C	D
		Erwartungswert	20,000	30,000	40,000	50,000
		99.9%-Quantil	1,000,000	1,000,000	1,000,000	1,000,000
	lambda	Anteil Datenverlust durch Threshold	65%	45%	33%	26%
1	5		1.8	2.7	3.3	3.7
2	10		3.5	5.5	6.7	7.4
3	25		8.8	13.7	16.7	18.5
4	50		17.5	27.5	33.3	37.1
5	100		35.1	54.9	66.7	74.2
6	250		87.7	137.3	166.7	185.4

Tabelle 6.7.: Kurzdarstellung der Modellspezifikation des Modells Log–Par. Mit den Spalten variiert der Erwartungswert eines einzelnen Verlustes (Parameterausprägung Höhe A–D); mit den Zeilen variiert der Häufigkeitsparameter λ (Parameterausprägung Häufigkeit 1–6). Aus der Kombination ergeben sich die simulierten Parameterausprägungen (A1–D6). Dargestellt ist der tatsächliche Erwartungswert für die Verlustanzahl eines einzelnen Jahres nach Berücksichtigung des Thresholds von 10.000.

Modell		A	B	C	D
Pareto	α	1.49 E+0	1.90 E+0	2.29 E+0	2.73 E+0
	θ	9.82 E+3	2.69 E+4	5.17 E+4	8.64 E+4

Tabelle 6.8.: Darstellung der berechneten Werte für die Parameter der Höhenverteilung. Der Erwartungswert entspricht jeweils dem in Tabelle 6.7 dargestellten Betrag von 20.000–50.000. Das 99.9%-Quantil eines einzelnen Verlustes ist 1.000.000. Daraus werden die hier angegebenen Parameter berechnet. Falls aufgrund dieser Vorgaben noch keine eindeutige Ermittlung der Parameter möglich ist, wird die Parameterkombination verwendet, die den Anteil der Verluste oberhalb des Thresholds maximiert.

gen 6.5 und 6.6, dass die Anzahl von 1.000.000 Iterationen für eine genaue Schätzung womöglich nicht ausreicht. Falls in der Praxis genauere Werte notwendig sind, müsste die Anzahl der Iterationen deutlich erhöht werden. Dies würde die Dauer der einzelnen Simulation verlängern, so dass im Rahmen dieser Arbeit darauf verzichtet wurde, da genaue Werte an dieser Stelle nicht entscheidend sind, sondern ein Überblick über zu erwartende Konfidenzintervalle gegeben werden soll.

Im Vergleich zum Modell Log–Log zeigt sich im Modell Log–Par, dass aufgrund der Änderung der Höhenverteilung im DGP die tatsächliche Höhe des OpVaR bzw. des ES deutlich ansteigt. Für die Parameterausprägungen A1 bzw. D6 beträgt der OpVaR 3.2 Mio. bzw. 21.4 Mio. Demgegenüber steht im Modell Log–Log ein OpVaR von 2.3 Mio. bzw. 19.2 Mio.

In der Übersicht der Konfidenzintervalle in den Tabellen 6.11 und 6.12 zeigt sich, dass durch die Annahme einer Lognormalverteilung für die Verlusthöhe der OpVaR sowie der ES tendenziell unterschätzt werden. Bei Modell D6 beträgt z.B. der wahre Wert für den OpVaR 21.4 Millionen, das 95% Quantil der Schätzergebnisse ergibt jedoch lediglich einen Wert von ca. 20.5 Millionen.




Abbildung 6.5.: In dieser Abbildung wird die MCS zur Ermittlung des tatsächlichen OpVaR beispielhaft für die Parameterausprägung A1 des Modells Log-Par dargestellt. Es zeigt sich, dass nach ungefähr 300.000 Iterationen die MCS bereits ausreichend stabil wird. Möglicherweise würde sich durch eine erhöhte Zahl Iterationen der endgültige Wert noch leicht ändern. Dadurch würden die Simulationen deutlich länger dauern, wobei sich die Ergebnisse nur unwesentlich ändern würden. Eine Darstellung der MCS für die übrigen Parameterausprägungen findet sich im Anhang.

Modell	A	B	C	D
1	3.2	2.6	2.3	2.2
2	4.8	3.8	3.2	3.1
3	9.1	6.4	5.2	4.9
4	14.9	9.6	7.9	7.2
5	24.5	14.7	11.9	11.2
6	45.7	26.5	21.9	21.4

Tabelle 6.9.: Übersicht über die tatsächliche Höhe des OpVaR für das Modell Log-Par für alle Parameterausprägungen jeweils in Millionen. Die Ergebnisse wurden mit einer MCS mit 1.000.000 Iterationen gewonnen.




Abbildung 6.6.: In dieser Abbildung wird die MCS zur Ermittlung des tatsächlichen ES beispielhaft für die Parameterausprägung A1 des Modells Log-Par dargestellt. Es zeigt sich, dass nach ungefähr 700.000 Iterationen die MCS bereits ausreichend stabil wird. Möglicherweise würde sich durch eine erhöhte Zahl Iterationen der endgültige Wert noch leicht ändern. Dadurch würden die Simulationen deutlich länger dauern, wobei sich die Ergebnisse nur unwesentlich ändern würden. Eine Darstellung der MCS für die übrigen Parameterausprägungen findet sich im Anhang.

Modell	A	B	C	D
1	9.1	5.2	3.9	3.3
2	13.3	7.8	5.6	4.6
3	25.2	13.3	8.6	7.1
4	41.7	18.0	12.3	10.0
5	65.1	26.8	17.9	14.6
6	121.2	46.7	30.6	26.0

Tabelle 6.10.: Übersicht über die tatsächliche Höhe des ES für das Modell Log-Par für alle Parameterausprägungen jeweils in Millionen. Die Ergebnisse wurden mit einer MCS mit 1.000.000 Iterationen gewonnen.




Abbildung 6.7.: Diese Grafik zeigt die Schwankungen des geschätzten OpVaR für das Modell Log-Par mit Parameterausprägung A1. Die Höhenverteilung des DGP folgt einer Paretoverteilung mit den Parametern $\alpha = 1.49$ und $\theta = 9.82 \cdot 10^3$. Die Häufigkeitsverteilung folgt einer Poissonverteilung mit dem Parameter $\lambda = 5$. Der tatsächliche OpVaR für diese Parameterausprägung beträgt ca. 3 Mio. Für die Schätzung wird als Höhenverteilung die Lognormalverteilung angenommen und als Häufigkeitsverteilung die Poissonverteilung. Es ist ersichtlich, dass der geschätzte OpVaR in vielen Fällen unterhalb des tatsächlichen Wertes liegt; es gibt zusätzlich große Abweichungen sowohl nach unten als auch nach oben. In 95% der Fälle liegt der Wert über 0.15 Mio; in 95% der Fälle liegt er unter 9.3 Mio. Dies entspricht Schwankungen von 95% nach unten und 193% nach oben.




Abbildung 6.8.: Diese Grafik zeigt die Schwankungen des geschätzten ES für das Modell Log-Par mit Parameterausprägung A1. Die Höhenverteilung des DGP folgt einer Paretoverteilung mit den Parametern $\alpha = 1.49$ und $\theta = 9.82 \cdot 10^3$. Die Häufigkeitsverteilung folgt einer Poissonverteilung mit dem Parameter $\lambda = 5$. Der tatsächliche ES für diese Parameterausprägung beträgt ca. 9 Mio. Für die Schätzung wird als Höhenverteilung die Lognormalverteilung angenommen und als Häufigkeitsverteilung die Poissonverteilung. Es ist ersichtlich, dass der geschätzte ES in vielen Fällen unterhalb des tatsächlichen Wertes liegt; es gibt zusätzlich große Abweichungen sowohl nach unten als auch nach oben. In 95% der Fälle liegt der Wert über 0.17 Mio; in 95% der Fälle liegt er unter 26.0 Mio. Dies entspricht Schwankungen von 98% nach unten und 185% nach oben.

Modell		A		B		C		D	
	Quantil	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler
1	5%	152,956	95%	257,505	90%	426,370	82%	558,841	74%
	95%	9,260,657	193%	9,827,171	276%	10,286,770	346%	6,151,237	181%
2	5%	296,939	94%	567,048	85%	856,872	74%	1,127,337	63%
	95%	17,421,353	262%	14,239,741	275%	9,111,728	181%	8,246,766	169%
3	5%	805,350	91%	1,373,831	79%	1,971,190	62%	2,418,150	51%
	95%	23,858,284	161%	10,751,817	67%	7,078,449	35%	7,378,112	50%
4	5%	1,739,993	88%	2,573,944	73%	3,448,600	56%	4,274,337	41%
	95%	27,326,611	83%	9,477,634	-1%	8,330,712	6%	8,191,203	14%
5	5%	3,508,693	86%	4,741,687	68%	6,197,612	48%	7,437,723	34%
	95%	31,541,003	28%	12,049,824	-18%	10,481,086	-12%	11,401,568	1%
6	5%	8,093,122	82%	10,352,903	61%	13,275,541	39%	16,537,179	23%
	95%	35,204,125	-23%	16,893,543	-36%	17,877,827	-18%	20,534,580	-4%

Tabelle 6.11.: Übersicht über die Konfidenzintervalle und die relativen Fehler für den OpVaR für alle Parameterausprägungen für das Modell Log-Par. Die tatsächlichen OpVaR sind in Tabelle 6.9 dargestellt. Es zeigt sich, dass bei einer geringen Anzahl Verluste der tatsächliche VaR sowohl stark überschätzt als auch stark unterschätzt werden kann. Wenn die Anzahl der Verluste steigt, führt die Verteilungsannahme dazu, dass der OpVaR fast ausschließlich unterschätzt wird.

Modell		A		B		C		D	
	Quantil	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler
1	5%	167,445	98%	286,422	95%	483,581	88%	641,707	81%
	95%	25,964,483	185%	26,864,481	413%	21,572,715	454%	9,687,906	190%
2	5%	324,616	98%	640,290	92%	966,937	83%	1,302,208	72%
	95%	48,131,028	262%	30,315,772	291%	15,308,713	174%	12,719,370	178%
3	5%	907,769	96%	1,560,159	88%	2,147,045	75%	2,715,332	62%
	95%	61,280,290	144%	18,245,702	37%	9,926,784	16%	9,827,955	38%
4	5%	2,079,049	95%	2,824,973	84%	3,839,565	69%	4,726,217	53%
	95%	63,313,896	52%	13,556,312	-25%	10,933,057	-11%	9,934,160	0%
5	5%	4,160,576	94%	5,251,229	80%	6,744,373	62%	8,015,491	45%
	95%	64,920,633	0%	16,464,498	-39%	12,490,091	-30%	12,995,362	-11%
6	5%	9,481,504	92%	11,247,965	76%	13,977,687	54%	17,380,551	33%
	95%	60,628,860	-50%	20,224,070	-57%	19,766,037	-35%	22,069,098	-15%

Tabelle 6.12.: Übersicht über die Konfidenzintervalle und die relativen Fehler für den ES für alle Parameterausprägungen für das Modell Log-Par. Die tatsächlichen ES sind in Tabelle 6.10 dargestellt. Es zeigt sich, dass bei einer geringen Anzahl Verluste der tatsächliche ES sowohl stark überschätzt als auch stark unterschätzt werden kann. Wenn die Anzahl der Verluste steigt, führt die Verteilungsannahme dazu, dass der ES fast ausschließlich unterschätzt wird.

6.3.3. Modell Lognormal–Weibull

Wie auch das Modell Log–Par, entspricht auch das Modell Lognormal–Weibull (Log–Wei) im Wesentlichen dem Modell Log–Log. Im Gegensatz zum vorherigen Modell ist die Verlusthöhenverteilung des DGP jedoch keine Pareto-, sondern eine Weibullverteilung. Die Ergebnisse werden so aufbereitet und in Tabellen und Grafiken dargestellt wie auch bei den Modellen Log–Log und Log–Par.

Wie den Tabellen 6.15 und 6.16 entnommen werden kann, nimmt die tatsächliche Höhe sowohl des OpVaR als auch des ES im Vergleich zum Modell Log–Log ab.

Bei der Betrachtung der Konfidenzintervalle mit größeren Werten für den Parameter λ und somit geringeren Fehlern für die Schätzung zeigt es sich, dass die Annahme der Lognormalverteilung die Verlusthöhen tendenziell überschätzt. Beim Modell D6 liegt der wahre Wert für den OpVaR z.B bei 18.8 Millionen. Die Untergrenze der Schätzergebnisse jedoch bereits bei 20.2 Millionen. Hier wird deutlich, dass die Auswahl der Verteilung

Modell			A	B	C	D
		Erwartungswert	20,000	30,000	40,000	50,000
		99.9%-Quantil	1,000,000	1,000,000	1,000,000	1,000,000
	lambda	Anteil Datenverlust durch Threshold	75%	62%	52%	43%
1	5		1.3	1.9	2.4	2.9
2	10		2.5	3.8	4.8	5.7
3	25		6.3	9.4	12.1	14.3
4	50		12.5	18.8	24.1	28.6
5	100		25.0	37.6	48.3	57.2
6	250		62.5	94.1	120.7	143.0

Tabelle 6.13.: Kurzdarstellung der Modellspezifikation des Modells Log–Wei. Mit den Spalten variiert der Erwartungswert eines einzelnen Verlustes (Parameterausprägung Höhe A–D); mit den Zeilen variiert der Häufigkeitsparameter λ (Parameterausprägung Häufigkeit 1–6). Aus der Kombination ergeben sich die simulierten Parameterausprägungen (A1–D6). Dargestellt ist der tatsächliche Erwartungswert für die Verlustanzahl eines einzelnen Jahres nach Berücksichtigung des Thresholds von 10.000.

Modell		A	B	C	D
Weibull	τ	3.49 E-1	4.25 E-1	4.89 E-1	5.46 E-1
	θ	3.94 E+3	1.06 E+4	1.91 E+4	2.91 E+4

Tabelle 6.14.: Darstellung der berechneten Werte für die Parameter der Höhenverteilung. Der Erwartungswert entspricht jeweils dem in Tabelle 6.13 dargestellten Betrag von 20.000–50.000. Das 99.9%-Quantil eines einzelnen Verlustes ist 1.000.000. Daraus werden die hier angegebenen Parameter berechnet. Falls aufgrund dieser Vorgaben noch keine eindeutige Ermittlung der Parameter möglich ist, wird die Parameterkombination verwendet, die den Anteil der Verluste oberhalb des Thresholds maximiert.

Modell	A	B	C	D
1	2.0	1.9	1.8	1.8
2	2.5	2.4	2.4	2.5
3	3.6	3.5	3.6	3.8
4	4.8	4.8	5.3	5.8
5	6.8	7.2	8.2	9.3
6	11.4	13.3	15.9	18.8

Tabelle 6.15.: Übersicht über die tatsächliche Höhe des OpVaR für das Modell Log-Wei für alle Parameterausprägungen jeweils in Millionen. Die Ergebnisse wurden mit einer MCS mit 1.000.000 Iterationen gewonnen.

für die Verlusthöhen an Einfluss gewinnt, je kleiner die Schwankungen der Werte und somit je vermeintlich genauer die Schätzergebnisse werden.

Modell	A	B	C	D
1	2.7	2.4	2.2	2.2
2	3.4	3.0	2.8	2.8
3	4.7	4.1	4.1	4.3
4	6.0	5.6	5.8	6.3
5	8.0	8.0	8.8	9.9
6	12.9	14.3	16.7	19.5

Tabelle 6.16.: Übersicht über die tatsächliche Höhe des ES für das Modell Log-Wei für alle Parameterausprägungen jeweils in Millionen. Die Ergebnisse wurden mit einer MCS mit 1.000.000 Iterationen gewonnen.




Abbildung 6.9.: In dieser Abbildung wird die MCS zur Ermittlung des tatsächlichen OpVaR beispielhaft für die Parameterausprägung A1 des Modells Log-Wei dargestellt. Es zeigt sich, dass nach ungefähr 100.000 Iterationen die MCS bereits ausreichend stabil wird. Eine Darstellung der MCS für die übrigen Parameterausprägungen findet sich im Anhang.




Abbildung 6.10.: In dieser Abbildung wird die MCS zur Ermittlung des tatsächlichen ES beispielhaft für die Parameterausprägung A1 des Modells Log-Wei dargestellt. Es zeigt sich, dass nach ungefähr 150.000 Iterationen die MCS bereits ausreichend stabil wird. Eine Darstellung der MCS für die übrigen Parameterausprägungen findet sich im Anhang.




Abbildung 6.11.: Diese Grafik zeigt die Schwankungen des geschätzten OpVaR für das Modell Log-Wei mit Parameterausprägung A1. Die Höhenverteilung des DGP folgt einer Weibullverteilung mit den Parametern $\tau = 3.49 \cdot 10^{-1}$ und $\theta = 3.94 \cdot 10^3$. Die Häufigkeitsverteilung folgt einer Poissonverteilung mit dem Parameter $\lambda = 5$. Der tatsächliche OpVaR für diese Parameterausprägung beträgt ca. 2.0 Mio. Für die Schätzung wird als Höhenverteilung die Lognormalverteilung angenommen und als Häufigkeitsverteilung die Poissonverteilung. Es ist ersichtlich, dass der geschätzte OpVaR in vielen Fällen unterhalb des tatsächlichen Wertes liegt; es gibt zusätzlich große Abweichungen sowohl nach unten als auch nach oben. In 95% der Fälle liegt der Wert über 0.22 Mio; in 95% der Fälle liegt er unter 34.8 Mio. Dies entspricht Schwankungen von 89% nach unten und 1681% nach oben. In vielen Fällen wird der OpVaR also deutlich überschätzt.




Abbildung 6.12.: Diese Grafik zeigt die Schwankungen des geschätzten ES für das Modell Log-Wei mit Parameterausprägung A1. Die Höhenverteilung des DGP folgt einer Paretoverteilung mit den Parametern $\tau = 3.49 \cdot 10^{-1}$ und $\theta = 3.94 \cdot 10^3$. Die Häufigkeitsverteilung folgt einer Poissonverteilung mit dem Parameter $\lambda = 5$. Der tatsächliche ES für diese Parameterausprägung beträgt ca. 2.7 Mio. Für die Schätzung wird als Höhenverteilung die Lognormalverteilung angenommen und als Häufigkeitsverteilung die Poissonverteilung. Es ist ersichtlich, dass der geschätzte ES in vielen Fällen unterhalb des tatsächlichen Wertes liegt; es gibt zusätzlich große Abweichungen sowohl nach unten als auch nach oben. In 95% der Fälle liegt der Wert über 0.25 Mio; in 95% der Fälle liegt er unter 118.5 Mio. Dies entspricht Schwankungen von 91% nach unten und 4216% nach oben. In vielen Fällen wird der ES also deutlich überschätzt.

Modell		A		B		C		D	
	Quantil	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler
1	5%	215,419	89%	317,112	83%	471,375	74%	553,546	70%
	95%	34,787,958	1681%	17,644,658	851%	17,543,594	861%	16,098,990	772%
2	5%	503,844	80%	753,437	68%	986,266	58%	1,465,628	40%
	95%	22,268,101	779%	32,042,619	1248%	21,563,028	809%	15,364,668	526%
3	5%	1,306,662	64%	1,980,537	43%	2,682,682	26%	3,143,704	18%
	95%	34,812,312	865%	17,842,975	415%	14,718,800	306%	14,234,759	271%
4	5%	2,645,795	45%	3,764,273	22%	4,677,698	11%	5,626,804	3%
	95%	28,541,019	489%	18,687,938	285%	16,394,323	212%	14,115,352	143%
5	5%	5,235,490	23%	6,653,676	8%	8,042,755	2%	9,729,573	-5%
	95%	28,184,105	316%	21,064,661	192%	18,287,557	123%	18,779,935	102%
6	5%	10,777,800	6%	14,151,825	-6%	17,205,973	-8%	20,254,931	-8%
	95%	31,720,124	178%	27,436,340	106%	27,468,352	72%	28,998,869	54%

Tabelle 6.17.: Übersicht über die Konfidenzintervalle und die relativen Fehler für den OpVaR für alle Parameterausprägungen für das Modell Log-Wei. Die tatsächlichen OpVaR sind in Tabelle 6.15 dargestellt. Es zeigt sich, dass bei einer geringen Anzahl Verluste der tatsächliche VaR sowohl stark überschätzt als auch stark unterschätzt werden kann. Wenn die Anzahl der Verluste steigt, führt die Verteilungsannahme dazu, dass der OpVaR fast ausschließlich überschätzt wird.

Modell		A		B		C		D	
	Quantil	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler
1	5%	250,512	91%	374,340	84%	545,230	76%	669,285	70%
	95%	118,503,393	4216%	47,300,638	1874%	36,264,800	1524%	32,500,531	1372%
2	5%	610,162	82%	938,514	68%	1,169,432	59%	1,734,288	39%
	95%	58,983,619	1629%	81,787,171	2655%	42,886,585	1406%	28,370,119	896%
3	5%	1,611,833	65%	2,401,887	42%	3,252,313	21%	3,692,903	14%
	95%	85,908,529	1746%	34,975,290	748%	22,544,588	445%	21,669,559	407%
4	5%	3,213,452	47%	4,489,920	20%	5,508,744	5%	6,540,645	-4%
	95%	51,463,443	755%	30,390,386	441%	24,747,088	326%	19,596,620	212%
5	5%	6,625,057	18%	8,032,917	0%	9,415,830	-7%	11,162,804	-13%
	95%	47,592,086	492%	30,925,948	286%	24,946,419	184%	24,292,396	146%
6	5%	13,249,553	-3%	16,709,249	-17%	19,413,000	-16%	22,357,307	-15%
	95%	46,843,600	263%	37,368,435	162%	34,087,212	104%	33,854,797	74%

Tabelle 6.18.: Übersicht über die Konfidenzintervalle und die relativen Fehler für den ES für alle Parameterausprägungen für das Modell Log-Wei. Die tatsächlichen ES sind in Tabelle 6.16 dargestellt. Es zeigt sich, dass bei einer geringen Anzahl Verluste der tatsächliche ES sowohl stark überschätzt als auch stark unterschätzt werden kann. Wenn die Anzahl der Verluste steigt, führt die Verteilungsannahme dazu, dass der ES fast ausschließlich überschätzt wird.

Modell			A	B	C	D
	lambda	Erwartungswert	20,000	30,000	40,000	50,000
		99.9%-Quantil	1,000,000	1,000,000	1,000,000	1,000,000
		Anteil Datenverlust durch Threshold	84%	74%	65%	56%
1	5		0.8	1.3	1.8	2.2
2	10		1.6	2.6	3.5	4.4
3	25		4.0	6.4	8.8	11.0
4	50		8.0	12.8	17.5	22.0
5	100		16.0	25.6	35.0	44.0
6	250		39.9	63.9	87.6	109.9

Tabelle 6.19.: Kurzdarstellung der Modellspezifikation des Modells Log–Gam. Mit den Spalten variiert der Erwartungswert eines einzelnen Verlustes (Parameterausprägung Höhe A–D); mit den Zeilen variiert der Häufigkeitsparameter λ (Parameterausprägung Häufigkeit 1–6). Aus der Kombination ergeben sich die simulierten Parameterausprägungen (A1–D6). Dargestellt ist der tatsächliche Erwartungswert für die Verlustanzahl eines einzelnen Jahres nach Berücksichtigung des Thresholds von 10.000.

Modell		A	B	C	D
Gamma	α	5.70 E-2	1.01 E-1	1.51 E-1	2.07 E-1
	θ	3.51 E+5	2.96 E+5	2.64 E+5	2.41 E+5

Tabelle 6.20.: Darstellung der berechneten Werte für die Parameter der Höhenverteilung. Der Erwartungswert entspricht jeweils dem in Tabelle 6.19 dargestellten Betrag von 20.000–50.000. Das 99.9%-Quantil eines einzelnen Verlustes ist 1.000.000. Daraus werden die hier angegebenen Parameter berechnet. Falls aufgrund dieser Vorgaben noch keine eindeutige Ermittlung der Parameter möglich ist, wird die Parameterkombination verwendet, die den Anteil der Verluste oberhalb des Thresholds maximiert.

6.3.4. Modell Lognormal–Gamma

Wie auch das Modell Log–Par, entspricht auch das Modell Lognormal–Gamma (Log–Gam) im Wesentlichen dem Modell Log–Log. Im Gegensatz zum vorherigen Modell ist die Verlusthöhenverteilung des DGP jedoch keine Weibull-, sondern eine Gammaverteilung.




Abbildung 6.13.: In dieser Abbildung wird die MCS zur Ermittlung des tatsächlichen OpVaR beispielhaft für die Parameterausprägung A1 des Modells Log-Gam dargestellt. Es zeigt sich, dass nach ungefähr 100.000 Iterationen die MCS bereits ausreichend stabil wird. Eine Darstellung der MCS für die übrigen Parameterausprägungen findet sich im Anhang.

Modell	A	B	C	D
1	1.7	1.7	1.8	1.8
2	2.0	2.1	2.3	2.4
3	2.9	3.2	3.5	3.9
4	3.9	4.5	5.2	5.9
5	5.7	7.0	8.2	9.5
6	10.2	13.2	16.2	19.2

Tabelle 6.21.: Übersicht über die tatsächliche Höhe des OpVaR für das Modell Log-Gam für alle Parameterausprägungen jeweils in Millionen. Die Ergebnisse wurden mit einer MCS mit 1.000.000 Iterationen gewonnen.




Abbildung 6.14.: In dieser Abbildung wird die MCS zur Ermittlung des tatsächlichen ES beispielhaft für die Parameterausprägung A1 des Modells Log-Gam dargestellt. Es zeigt sich, dass nach ungefähr 200.000 Iterationen die MCS bereits ausreichend stabil wird. Möglicherweise würde sich durch eine erhöhte Zahl Iterationen der endgültige Wert noch leicht ändern. Dadurch würden die Simulationen deutlich länger dauern, wobei sich die Ergebnisse nur unwesentlich ändern würden. Eine Darstellung der MCS für die übrigen Parameterausprägungen findet sich im Anhang.

Modell	A	B	C	D
1	2.0	2.0	2.0	2.1
2	2.4	2.4	2.5	2.7
3	3.2	3.5	3.9	4.2
4	4.3	4.9	5.6	6.3
5	6.2	7.4	8.7	10.0
6	10.9	13.9	16.8	19.9

Tabelle 6.22.: Übersicht über die tatsächliche Höhe des ES für das Modell Log-Gam für alle Parameterausprägungen jeweils in Millionen. Die Ergebnisse wurden mit einer MCS mit 1.000.000 Iterationen gewonnen.




Abbildung 6.15.: Diese Grafik zeigt die Schwankungen des geschätzten OpVaR für das Modell Log-Gam mit Parameterausprägung A1. Die Höhenverteilung des DGP folgt einer Gammaverteilung mit den Parametern $\alpha = 5.70 \cdot 10^{-2}$ und $\theta = 3.51 \cdot 10^5$. Die Häufigkeitsverteilung folgt einer Poissonverteilung mit dem Parameter $\lambda = 5$. Der tatsächliche OpVaR für diese Parameterausprägung beträgt ca. 1.7 Mio. Für die Schätzung wird als Höhenverteilung die Lognormalverteilung angenommen und als Häufigkeitsverteilung die Poissonverteilung. Es ist ersichtlich, dass der geschätzte OpVaR in vielen Fällen im Bereich des tatsächlichen Wertes liegt; es gibt zusätzlich große Abweichungen sowohl nach unten als auch nach oben. In 95% der Fälle liegt der Wert über 0.37 Mio; in 95% der Fälle liegt er unter 27.0 Mio. Dies entspricht Schwankungen von 77% nach unten und 1531% nach oben.




Abbildung 6.16.: Diese Grafik zeigt die Schwankungen des geschätzten ES für das Modell Log-Gam mit Parameterausprägung A1. Die Höhenverteilung des DGP folgt einer Gammaverteilung mit den Parametern $\alpha = 5.70 \cdot 10^{-2}$ und $\theta = 3.51 \cdot 10^5$. Die Häufigkeitsverteilung folgt einer Poissonverteilung mit dem Parameter $\lambda = 5$. Der tatsächliche ES für diese Parameterausprägung beträgt ca. 2.0 Mio. Für die Schätzung wird als Höhenverteilung die Lognormalverteilung angenommen und als Häufigkeitsverteilung die Poissonverteilung. Es ist ersichtlich, dass der geschätzte ES in vielen Fällen im Bereich des tatsächlichen Wertes liegt; es gibt zusätzlich große Abweichungen sowohl nach unten als auch nach oben. In 95% der Fälle liegt der Wert über 0.43 Mio; in 95% der Fälle liegt er unter 59.8 Mio. Dies entspricht Schwankungen von 77% nach unten und 1531% nach oben.

Modell		A		B		C		D	
	Quantil	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler
1	5%	374,601	77%	405,785	76%	530,599	70%	730,907	60%
	95%	26,996,242	1531%	20,410,930	1114%	26,453,419	1410%	14,919,698	721%
2	5%	474,977	77%	843,262	60%	1,121,134	50%	1,553,675	36%
	95%	55,778,974	2649%	27,580,001	1193%	23,874,355	959%	18,442,756	664%
3	5%	1,891,593	34%	2,789,018	12%	3,496,986	1%	4,057,581	-5%
	95%	31,081,193	989%	23,039,611	629%	19,705,252	458%	17,595,689	355%
4	5%	3,910,565	0%	4,668,916	-3%	5,988,630	-15%	7,254,301	-23%
	95%	29,187,157	645%	26,929,952	494%	20,050,129	284%	20,247,810	243%
5	5%	6,844,813	-20%	9,170,466	-32%	10,821,208	-32%	11,868,798	-25%
	95%	30,703,678	439%	26,229,669	277%	24,718,515	201%	24,786,373	161%
6	5%	14,293,907	-40%	18,237,769	-38%	20,968,324	-29%	24,545,413	-28%
	95%	36,773,020	260%	33,731,224	155%	33,430,416	106%	35,534,017	85%

Tabelle 6.23.: Übersicht über die Konfidenzintervalle und die relativen Fehler für den OpVaR für alle Parameterausprägungen für das Modell Log-Gam. Die tatsächlichen OpVaR sind in Tabelle 6.21 dargestellt. Es zeigt sich, dass bei einer geringen Anzahl Verluste der tatsächliche VaR sowohl stark überschätzt als auch stark unterschätzt werden kann. Wenn die Anzahl der Verluste steigt, führt die Verteilungsannahme dazu, dass der OpVaR fast ausschließlich überschätzt wird.

Modell		A		B		C		D	
	Quantil	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler
1	5%	433,693	78%	477,589	76%	662,226	67%	869,261	58%
	95%	59,779,494	2916%	50,246,060	2451%	64,746,087	3124%	29,404,272	1323%
2	5%	558,311	76%	1,028,122	58%	1,311,615	48%	1,901,735	29%
	95%	219,458,650	9177%	56,800,194	2229%	50,706,616	1900%	31,566,617	1070%
3	5%	2,360,019	27%	3,506,695	0%	4,511,008	-17%	4,994,347	-18%
	95%	56,088,915	1641%	38,545,133	1000%	31,332,319	709%	27,258,771	546%
4	5%	5,028,757	-16%	5,845,649	-19%	7,266,431	-29%	8,799,522	-39%
	95%	52,372,026	1111%	42,911,875	771%	29,292,505	421%	29,149,257	362%
5	5%	8,867,786	-44%	11,478,338	-54%	13,226,195	-52%	14,304,617	-44%
	95%	48,566,299	688%	37,867,736	409%	34,117,554	293%	33,377,501	235%
6	5%	17,946,842	-65%	22,043,181	-59%	24,547,967	-46%	27,792,283	-40%
	95%	53,474,917	392%	44,793,253	223%	42,467,929	152%	43,553,938	119%

Tabelle 6.24.: Übersicht über die Konfidenzintervalle und die relativen Fehler für den ES für alle Parameterausprägungen für das Modell Log-Gam. Die tatsächlichen ES sind in Tabelle 6.22 dargestellt. Es zeigt sich, dass bei einer geringen Anzahl Verluste der tatsächliche ES sowohl stark überschätzt als auch stark unterschätzt werden kann. Wenn die Anzahl der Verluste steigt, führt die Verteilungsannahme dazu, dass der ES fast ausschließlich überschätzt wird.

6.3.5. Modell Lognormal–Mischung

Beim Modell Lognormal–Mischung (Log–Mis) ist die Höhenverteilung des DGP nicht mehr fest vorgegeben. Stattdessen wird jeder Verlust mit gleicher Wahrscheinlichkeit aus einer der vier Möglichkeiten Lognormalverteilung, Paretoverteilung, Weibullverteilung oder Gammaverteilung generiert. Im Schätzmodell wird jedoch weiterhin lediglich von einer Lognormalverteilung ausgegangen. Die vier Verteilungen sind durch die gewählten Parameter miteinander vergleichbar. Innerhalb eines Modelltyps hat jede den gleichen Erwartungswert und das gleiche 99.9%-Quantil.

Die Spezifikationen des Modells Log–Mis werden in Tabelle 6.25 dargestellt. Im Vergleich zum Modell Log–Log steigt auch im Modell Log–Mis der Anteil der Daten, die aufgrund des Thresholds von 10.000 nicht in die Verlustdatenbank aufgenommen werden und somit nicht für die Schätzungen verwendet werden können. Selbst für Parameterausprägung D ist dieser Anteil noch größer als der für die Parameterausprägung C im

Modell			A	B	C	D
		Erwartungswert	20,000	30,000	40,000	50,000
		99.9%-Quantil	1,000,000	1,000,000	1,000,000	1,000,000
	lambda	Anteil Datenverlust durch Threshold	73%	58%	46%	37%
1	5		1.3	2.1	2.7	3.2
2	10		2.7	4.2	5.4	6.3
3	25		6.7	10.5	13.4	15.8
4	50		13.4	20.9	26.9	31.5
5	100		26.7	41.9	53.7	63.1
6	250		66.9	104.7	134.3	157.6

Tabelle 6.25.: Kurzdarstellung der Modellspezifikation des Modells Log–Mis. Mit den Spalten variiert der Erwartungswert eines einzelnen Verlustes (Parameterausprägung Höhe A–D); mit den Zeilen variiert der Häufigkeitsparameter λ (Parameterausprägung Häufigkeit 1–6). Aus der Kombination ergeben sich die simulierten Parameterausprägungen (A1–D6). Dargestellt ist der tatsächliche Erwartungswert für die Verlustanzahl eines einzelnen Jahres nach Berücksichtigung des Thresholds von 10.000.

Modell		A	B	C	D
Lognormal	μ	8.33 E+0	8.19 E+0	9.71 E+0	1.01 E+1
	σ	1.78 E+0	1.50 E+0	1.33 E+0	1.20 E+0
Pareto	α	1.49 E+0	1.90 E+0	2.29 E+0	2.73 E+0
	θ	9.82 E+3	2.69 E+4	5.17 E+4	8.64 E+4
Weibull	τ	3.49 E-1	4.25 E-1	4.89 E-1	5.46 E-1
	θ	3.94 E+3	1.06 E+4	1.91 E+4	2.91 E+4
Gamma	α	5.70 E-2	1.01 E-1	1.51 E-1	2.07 E-1
	θ	3.51 E+5	2.96 E+5	2.64 E+5	2.41 E+5

Tabelle 6.26.: Darstellung der berechneten Werte für die Parameter der Höhenverteilung. Der Erwartungswert entspricht jeweils dem in Tabelle 6.13 dargestellten Betrag von 20.000–50.000. Das 99.9%-Quantil eines einzelnen Verlustes ist 1.000.000. Daraus werden die hier angegebenen Parameter berechnet. Falls aufgrund dieser Vorgaben noch keine eindeutige Ermittlung der Parameter möglich ist, wird die Parameterkombination verwendet, die den Anteil der Verluste oberhalb des Thresholds maximiert.

Modell Log–Log. Die aus den vorgegebenen Werten ermittelten Parameter der Höhenverteilungen finden sich in Tabelle 6.26.

Wie auch in den übrigen Modellen wird für das Modell Log–Mis zunächst ermittelt, wie groß der tatsächliche OpVaR bzw. der ES sind. In den Abbildungen 6.17 und 6.18 ist dies erneut für die Parameterausprägung A1 dargestellt. Es zeigt sich auch hier, dass bei der vielfachen Durchführung der MCS 200.000 bzw. 300.000 Iterationen ausreichen, um eine angemessene Genauigkeit zu erzielen. Die Übersicht über die Ergebnisse findet sich in Tabelle 6.27 für den OpVaR und in Tabelle 6.28 für den ES. Im Vergleich zum Modell Log–Log treten hier sehr ähnliche Werte sowohl für den OpVaR als auch für den ES auf.

Im nächsten Schritt wird die MCS erneut 500-mal durchgeführt und die Histogramme erstellt und die Konfidenzintervalle sowie die relativen Abweichungen bestimmt. Das Histogramm für Modell A1 wird in Abbildung 6.19 gezeigt. Auch hier wurde wieder eine exponentielle Darstellung für die Klassenobergrenzen gewählt.




Abbildung 6.17.: In dieser Abbildung wird die MCS zur Ermittlung des tatsächlichen OpVaR beispielhaft für die Parameterausprägung A1 des Modells Log-Mis dargestellt. Es zeigt sich, dass nach ungefähr 200.000 Iterationen die MCS bereits ausreichend stabil wird. Eine Darstellung der MCS für die übrigen Parameterausprägungen findet sich im Anhang.

In den beiden abschließenden Tabellen werden die Ergebnisse aller Schätzungen in einer Übersicht dargestellt. Die detaillierten Ergebnisse aller Parameterermittlungen und alle Histogramme finden wieder im Anhang. Ein interessanter Aspekt der wahren 99.9%-

Modell	A	B	C	D
1	2.2	2.0	1.9	1.9
2	2.9	2.7	2.6	2.6
3	5.0	4.2	4.0	4.2
4	7.5	6.3	6.1	6.3
5	12.0	9.4	9.3	9.9
6	22.3	17.8	17.8	19.5

Tabelle 6.27.: Übersicht über die tatsächliche Höhe des OpVaR für das Modell Log-Mis für alle Parameterausprägungen jeweils in Millionen. Die Ergebnisse wurden mit einer MCS mit 1.000.000 Iterationen gewonnen.




Abbildung 6.18.: In dieser Abbildung wird die MCS zur Ermittlung des tatsächlichen ES beispielhaft für die Parameterausprägung A1 des Modells Log–Mis dargestellt. Es zeigt sich, dass nach ungefähr 300.000 Iterationen die MCS bereits ausreichend stabil wird. Eine Darstellung der MCS für die übrigen Parameterausprägungen findet sich im Anhang.

Quantile zeigt sich bei Vergleich der Modelle A–D. In vielen Fällen ändert sich beim Übergang zu einer weiter rechts liegenden Spalte das Ergebnis kaum oder wird sogar kleiner. Dies hängt mit den verringerten Fluktuationen der Zufallszahlen zusammen,

Modell	A	B	C	D
1	4.4	3.3	2.9	2.6
2	13.6	4.7	3.7	3.4
3	11.0	7.0	5.7	5.3
4	16.9	10.4	8.3	7.8
5	28.6	15.2	12.5	11.7
6	53.0	29.4	22.9	21.7

Tabelle 6.28.: Übersicht über die tatsächliche Höhe des ES für das Modell Log–Wei für alle Parameterausprägungen jeweils in Millionen. Die Ergebnisse wurden mit einer MCS mit 1.000.000 Iterationen gewonnen.

Modell	Quantil	A		B		C		D	
		Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler
1	5%	193,770	91%	250,598	87%	471,724	76%	547,035	71%
	95%	24,328,018	1027%	19,560,944	896%	17,497,452	798%	11,906,121	522%
2	5%	367,310	87%	734,116	73%	949,203	64%	1,278,858	51%
	95%	32,630,091	1012%	22,005,936	710%	11,609,867	342%	10,347,666	293%
3	5%	1,175,156	77%	1,878,306	56%	2,420,704	40%	2,794,741	33%
	95%	62,302,067	1146%	22,968,057	443%	15,091,132	273%	11,166,051	167%
4	5%	2,643,979	65%	3,656,595	42%	4,259,195	30%	5,262,031	16%
	95%	49,918,441	563%	21,041,429	233%	14,315,838	136%	13,559,889	116%
5	5%	5,440,127	55%	6,657,087	29%	7,455,664	20%	8,951,098	10%
	95%	56,089,803	366%	21,873,697	134%	18,776,920	102%	16,015,253	61%
6	5%	12,580,769	44%	13,933,567	22%	16,282,518	8%	18,835,694	3%
	95%	51,562,604	131%	29,750,172	67%	24,949,717	41%	26,208,736	34%

Tabelle 6.29.: Übersicht über die Konfidenzintervalle und die relativen Fehler für den OpVaR für alle Parameterausprägungen für das Modell Log-Mis. Die tatsächlichen OpVaR sind in Tabelle 6.27 dargestellt. Es zeigt sich, dass bei einer geringen Anzahl Verluste der tatsächliche VaR sowohl stark überschätzt als auch stark unterschätzt werden kann. Wenn die Anzahl der Verluste steigt, werden die Konfidenzintervalle kleiner und schließen den tatsächlichen Wert immer ein.

da aufgrund des näheren Zusammenliegens von Erwartungswert und 99.9%-Quantil der einzelnen Verteilungen auch die Varianz der Verteilungen und damit auch die Varianz der generierten Zufallszahlen abnimmt.

Die berechneten Konfidenzintervalle sind in Tabelle 6.29 dargestellt. Wie zu vermuten gewesen ist, nimmt die Länge der Konfidenzintervalle in den meisten Fällen zu. Vor allem bei kleineren Häufigkeitsparametern sind die Schwankungen extrem groß, so dass für die Berechnung von Risiken ebenfalls große Sicherheitsfaktoren bestimmt werden müssten. Wenn als Beispiel wieder Modell A1 betrachtet wird, lässt sich aus Tabelle 6.29 erkennen, dass bei einem wahren 99.9%-Quantil von 2.1 Mio. in jedem 20. Fall ein Schätzergebnis von weniger als 204.801 ermittelt werden würde. Das bedeutet, dass mindestens ein Faktor von 10 auf entsprechende Rechnungen aufgeschlagen werden müsste, wobei an dieser Stelle nochmals betont sei, dass diese Ergebnisse auf extrem restriktiven Annahmen bezüglich der Datenqualität beruhen.

Modell	Quantil	A		B		C		D	
		Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler
1	5%	226,383	95%	279,310	92%	558,252	81%	626,717	76%
	95%	81,083,640	1749%	47,563,094	1344%	39,101,424	1264%	21,304,432	725%
2	5%	426,294	97%	882,539	81%	1,118,860	70%	1,530,151	55%
	95%	107,886,620	696%	57,113,828	1113%	20,644,396	451%	15,785,263	362%
3	5%	1,449,178	87%	2,288,654	67%	2,852,102	50%	3,299,739	38%
	95%	175,496,228	1502%	41,852,815	496%	24,878,558	335%	16,263,581	205%
4	5%	3,335,078	80%	4,311,584	58%	5,087,107	39%	6,096,556	22%
	95%	124,289,137	636%	33,707,715	225%	20,563,649	148%	18,201,232	134%
5	5%	7,064,234	75%	8,094,624	47%	8,570,545	31%	9,999,995	15%
	95%	111,998,180	292%	33,004,521	117%	25,329,840	103%	20,029,484	71%
6	5%	16,343,424	69%	16,459,015	44%	18,222,908	20%	20,436,373	6%
	95%	88,616,580	67%	41,434,135	41%	30,579,671	34%	29,842,128	38%

Tabelle 6.30.: Übersicht über die Konfidenzintervalle und die relativen Fehler für den ES für alle Parameterausprägungen für das Modell Log-Mis. Die tatsächlichen ES sind in Tabelle 6.16 dargestellt. Es zeigt sich, dass bei einer geringen Anzahl Verluste der tatsächliche ES sowohl stark überschätzt als auch stark unterschätzt werden kann. Wenn die Anzahl der Verluste steigt, werden die Konfidenzintervalle kleiner und schließen den tatsächlichen Wert immer ein.




Abbildung 6.19.: Diese Grafik zeigt die Schwankungen des geschätzten OpVaR für das Modell Log-Mis mit Parameterausprägung A1. Die Höhenverteilung des DGP folgt entweder einer Lognormalverteilung mit den Parametern $\mu = 8.33$ und $\sigma = 1.78$ oder einer Paretoverteilung mit den Parametern $\alpha = 1.49$ und $\theta = 9.82 \cdot 10^3$ oder einer Weibullverteilung mit den Parametern $\tau = 3.49 \cdot 10^{-1}$ und $\theta = 3.94 \cdot 10^3$ oder einer Gammaverteilung mit den Parametern $\alpha = 5.7 \cdot 10^{-2}$ und $\theta = 3.5 \cdot 10^5$. Bevor die Höhe ermittelt wird, wird die zu nutzende Verteilung bestimmt, wobei jede die gleiche Wahrscheinlichkeit besitzt. Die Häufigkeitsverteilung folgt einer Poissonverteilung mit dem Parameter $\lambda = 5$. Der tatsächliche OpVaR für diese Parameterausprägung beträgt ca. 2.2 Mio. Für die Schätzung wird als Höhenverteilung die Lognormalverteilung angenommen und als Häufigkeitsverteilung die Poissonverteilung. Es ist ersichtlich, dass der geschätzte OpVaR in vielen Fällen dem tatsächlichen Wert recht nahe kommt, es gibt jedoch große Abweichungen sowohl nach unten als auch nach oben. In 95% der Fälle liegt der Wert über 0.19 Mio; in 95% der Fälle liegt er unter 24.3 Mio. Dies entspricht Schwankungen von 91% nach unten und 1027% nach oben.




Abbildung 6.20.: Diese Grafik zeigt die Schwankungen des geschätzten ES für das Modell Log-Mis mit Parameterausprägung A1. Die Höhenverteilung des DGP folgt entweder einer Lognormalverteilung mit den Parametern $\mu = 8.33$ und $\sigma = 1.78$ oder einer Paretoverteilung mit den Parametern $\alpha = 1.49$ und $\theta = 9.82 \cdot 10^3$ oder einer Weibullverteilung mit den Parametern $\tau = 3.49 \cdot 10^{-1}$ und $\theta = 3.94 \cdot 10^3$ oder einer Gammaverteilung mit den Parametern $\alpha = 5.7 \cdot 10^{-2}$ und $\theta = 3.5 \cdot 10^5$. Bevor die Höhe ermittelt wird, wird die zu nutzende Verteilung bestimmt, wobei jede die gleiche Wahrscheinlichkeit besitzt. Die Häufigkeitsverteilung folgt einer Poissonverteilung mit dem Parameter $\lambda = 5$. Der tatsächliche ES für diese Parameterausprägung beträgt ca. 4.4 Mio. Für die Schätzung wird als Höhenverteilung die Lognormalverteilung angenommen und als Häufigkeitsverteilung die Poissonverteilung. Es ist ersichtlich, dass der geschätzte ES in vielen Fällen dem tatsächlichen Wert recht nahe kommt, es gibt jedoch große Abweichungen sowohl nach unten als auch nach oben. In 95% der Fälle liegt der Wert über 0.23 Mio; in 95% der Fälle liegt er unter 81.1 Mio. Dies entspricht Schwankungen von 95% nach unten und 1749% nach oben.

6.4. Modell unter Berücksichtigung von A-Priori-Informationen

In den bisher vorgestellten Modellen wurden ausschließlich Verlustdaten für die Quantifizierung genutzt. Dabei wurde die Tatsache vernachlässigt, dass für die Quantifizierung operationeller Risiken möglicherweise unterschiedliche Datenquellen zur Verfügung stehen. Um zu überprüfen, wie sich die Existenz zusätzlicher Informationen auf die Genauigkeit der Quantifizierung auswirkt, wurde in diesem Abschnitt angenommen, dass zusätzliche, quantitative Informationen zur Verfügung stehen, mit deren Hilfe eine A-Priori-Verteilung der zu schätzenden Parameter bestimmt werden kann. Dabei wurde die Frage, wie anhand der zusätzlichen Informationen wie z.B. externer Verlustdaten oder Self-Assessments die A-Priori-Verteilungen der Parameter konkret ermittelt werden können, nicht weiter betrachtet.

Als Basis wurde für den DGP das Modell Log-Log mit Parameterausprägung A1 genutzt. Die Schätzverfahren wurden angepasst, so dass diese zusätzliche Informationen bei den Schätzungen berücksichtigt wurden, um den Einfluss auf die Konfidenzintervalle zu analysieren. Dabei wurden zwei Aspekte berücksichtigt.

Zunächst wurde angenommen, welches Gewicht die zusätzlichen Informationen für die Bestimmung der zu schätzenden Parameter bekommen sollen, d.h. für wie zuverlässig diese Informationen gehalten werden. Falls sicher ist, dass die zusätzlichen Daten prinzipiell dem gleichen DGP entspringen, kann dies auch rechnerisch ermittelt werden, wie z.B. von Alexander (2003a) vorgeschlagen. Dort wird ein Verfahren nach Bayes vorgestellt, in welchem externe Verlustdaten als zusätzliche Informationen benutzt werden. Die Genauigkeit wird anhand der Varianz dieser Daten bestimmt. Falls die Daten jedoch fälschlich für genau gehalten werden, kann dies die Qualität der Schätzungen auch

verschlechtern, wie in den hier vorgestellten Modellen gezeigt wird. Da ein gleicher DGP nicht im Allgemeinen vorausgesetzt werden kann, ist das Gewicht der A-Priori-Informationen eine zusätzliche Annahme für die Schätzungen. Diese wurde durch die beiden Modelle BayHoch, bei dem die zusätzlichen Daten ein hohes Gewicht bekommen, und BayNiedrig, bei dem die zusätzlichen Daten lediglich ein geringes Gewicht bekommen realisiert.

Der zweite Aspekt betrifft die tatsächliche Genauigkeit der zusätzlichen Informationen, d.h. ob die zusätzlichen Daten tatsächlich dem gleichen DGP entstammen. Dazu wurden für beide Modelle jeweils neun Parameterausprägungen simuliert. Die A-Priori-Parameter μ und σ der Lognormalverteilung konnten dabei jeweils die drei Ausprägungen $0.5 \mu_{real}$, $1.0 \mu_{real}$ und $1.5 \mu_{real}$ bzw. $0.5 \sigma_{real}$, $1.0 \sigma_{real}$ und $1.5 \sigma_{real}$ annehmen. Damit wurde ein 50%-iges Über- bzw. Unterschätzen der Parameter sowie eine exakte Übereinstimmung der aus den zusätzlichen Informationen geschätzten Parametern mit dem DGP simuliert. Aus der Kombination der Möglichkeiten ergeben sich die neun Simulationen, die für jedes Modell durchgeführt wurden.

Die Verlusthäufigkeit wurde wie bereits in Abschnitt 6.3 mit Hilfe eines einfachen Momentenschätzers bestimmt.

6.4.1. Modell Bayes–hochgewichtet

Die Grafiken zeigen die Ergebnisse unter der Annahme, dass die A-Priori-Informationen sehr hoch gewichtet werden (Modell BayHoch). In Tabelle 6.31 wird zunächst die Modellspezifikation dargestellt. Dabei geben die Parameter κ_0 und ν_0 das Gewicht an, das die A-Priori-Informationen bekommen. Mit 100 wird hier ein Wert angegeben, der zu einem hohen Gewicht führt.

Die Grafiken 6.21, 6.22 und 6.23 zeigen die Histogramme mit den Schwankungen der

Modell	1	A	B	D
	2			
A		$\mu_0=0.5 \mu_{\text{real}}$ $\kappa_0=100$ $\sigma_0^2=0.5 \sigma_{\text{real}}$ $\nu_0=100$	$\mu_0=1.0 \mu_{\text{real}}$ $\kappa_0=100$ $\sigma_0^2=0.5 \sigma_{\text{real}}$ $\nu_0=100$	$\mu_0=1.5 \mu_{\text{real}}$ $\kappa_0=100$ $\sigma_0^2=0.5 \sigma_{\text{real}}$ $\nu_0=100$
B		$\mu_0=0.5 \mu_{\text{real}}$ $\kappa_0=100$ $\sigma_0^2=1.0 \sigma_{\text{real}}$ $\nu_0=100$	$\mu_0=1.0 \mu_{\text{real}}$ $\kappa_0=100$ $\sigma_0^2=1.0 \sigma_{\text{real}}$ $\nu_0=100$	$\mu_0=1.5 \mu_{\text{real}}$ $\kappa_0=100$ $\sigma_0^2=1.0 \sigma_{\text{real}}$ $\nu_0=100$
C		$\mu_0=0.5 \mu_{\text{real}}$ $\kappa_0=100$ $\sigma_0^2=1.5 \sigma_{\text{real}}$ $\nu_0=100$	$\mu_0=1.0 \mu_{\text{real}}$ $\kappa_0=100$ $\sigma_0^2=1.5 \sigma_{\text{real}}$ $\nu_0=100$	$\mu_0=1.5 \mu_{\text{real}}$ $\kappa_0=100$ $\sigma_0^2=1.5 \sigma_{\text{real}}$ $\nu_0=100$

Tabelle 6.31.: Kurzdarstellung der Modellspezifikation des Modells BayHoch. Das Modell basiert für die Schätzungen auf dem Modell Log-Log mit Parameterausprägung A1. Mit den Spalten variiert die A-Priori-Informationen über den Parameter μ , so dass dieser in Spalte A einen Wert annimmt der halb so groß ist, wie der reale Parameter des DGP, in Spalte B einen Wert, der dem Parameter μ des DGP entspricht und in Spalte C einen Wert, der 50% größer ist als der Parameter μ des DGP. Mit den Zeilen variiert die A-Priori-Information über den Parameter σ , so dass dieser wie schon der Parameter μ einen Wert annimmt der 50, 100 oder 150 Prozent des Parameters σ des DGP entspricht. Dabei wird die A-Priori-Information für die Parameter für sehr exakt gehalten; die Parameter κ_0 und ν_0 nehmen einen Wert von 100 an.

sich aus der dMCS ergebenden Resultate. Die Schwankungen sind bei allen Parameterausprägungen in Relation zum geschätzten Mittel kleiner als bei den Modellen ohne A-Priori-Informationen. Dies ist ein Vorteil, wenn diese Informationen wahre Voraussagen über den DGP machen können, wie in Parameterausprägung BB. Es kann jedoch auch ein großer Nachteil sein, wie bei den Parameterausprägungen AA und BB, wenn die Modellergebnisse ein Ergebnis sowie eine Schwankungsbreite suggerieren, die dem tatsächlichen DGP nicht mehr entspricht. In einem solchen Fall sollte daher auf die Nutzung zusätzlicher Informationen verzichtet werden; die Herausforderung in der Praxis besteht




Abbildung 6.21.: Diese Grafik zeigt die Schwankungen des geschätzten OpVaR für das Modell BayHoch falls die A-Priori-Informationen die tatsächlichen Parameter des DGP jeweils um 50% unterschätzen. Der DGP entspricht dem DGP aus dem Modell Log-Log. Der tatsächliche OpVaR beträgt ca. 2 Mio. Für die Schätzung wird das in Kapitel 3.4 dargestellte Verfahren zur Berücksichtigung der A-Priori-Informationen genutzt. Es ist ersichtlich, dass der geschätzte OpVaR den tatsächlichen Wert stark unterschätzt. In 95% der Fälle liegt der Wert unter 1.2 Mio.

nun darin, herauszufinden, ob die zusätzlichen Informationen valide sind oder nicht.

In Tabelle 6.32 findet sich eine Übersicht über die ermittelten Konfidenzintervalle. Es zeigt sich, dass die Parameter der A-Priori-Information einen starken Einfluss auf die Ergebnisse nehmen. Falls die Informationen die Parameter des DGP unterschätzen, ist auch das Ergebnis zu klein, falls die Parameter der A-Priori-Informationen die tatsächlichen Parameter des DGP exakt treffen, sind die Konfidenzintervalle deutlich kleiner als im Modell Log-Log bei identischer Parameterausprägung und, falls die Informationen die Parameter überschätzen, werden auch die Schätzungen zu große Werte ergeben. Al-




Abbildung 6.22.: Diese Grafik zeigt die Schwankungen des geschätzten OpVaR für das Modell BayHoch falls die A-Priori-Informationen die tatsächlichen Parameter des DGP exakt treffen. Der DGP entspricht dem DGP aus dem Modell Log-Log. Der tatsächliche OpVaR beträgt ca. 2 Mio. Für die Schätzung wird das in Kapitel 3.4 dargestellte Verfahren zur Berücksichtigung der A-Priori-Informationen genutzt. Es ist ersichtlich, dass der geschätzte OpVaR dem tatsächlichen Wert häufig relativ nahe kommt. In 95% der Fälle liegt der Wert über 1.9 Mio.; in 95% der Fälle liegt er unter 4.0 Mio. Dies entspricht Schwankungen von 18% nach unten und 68% nach oben.

le Tabellen und Grafiken sowie zusätzlich die Histogramme der hier nicht dargestellten Parameterausprägungen finden sich wieder im Anhang.




Abbildung 6.23.: Diese Grafik zeigt die Schwankungen des geschätzten OpVaR für das Modell BayHoch falls die A-Priori-Informationen die tatsächlichen Parameter des DGP jeweils um 50% überschätzen. Der DGP entspricht dem DGP aus dem Modell Log-Log. Der tatsächliche OpVaR beträgt ca. 2 Mio. Für die Schätzung wird das in Kapitel 3.4 dargestellte Verfahren zur Berücksichtigung der A-Priori-Informationen genutzt. Es ist ersichtlich, dass der geschätzte OpVaR den tatsächlichen Wert stark überschätzt. In 95% der Fälle liegt der Wert über 1.1 Mrd.

Modell	1 2 Quantil	A		B		C	
		Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler
A	5%	92,006	96%	414,074	82%	126,302,378	-5258%
	95%	1,218,882	-48%	1,057,770	-55%	647,485,234	27367%
B	5%	323,441	86%	1,944,238	18%	387,406,763	-16334%
	95%	3,023,375	28%	3,969,673	68%	1,568,145,845	66422%
C	5%	854,150	64%	6,439,216	-173%	1,094,419,101	-46326%
	95%	6,440,760	173%	12,043,091	411%	3,329,368,307	141134%

Tabelle 6.32.: Übersicht über die Konfidenzintervalle und die relativen Fehler für den OpVaR für alle Parameterausprägungen für das Modell BayHoch. Die tatsächlichen OpVaR sind weiter oben in Tabelle 6.3 dargestellt. Es zeigt sich, dass unter der Annahme, dass die A-Priori-Informationen sehr genau sind der Prior einen starken Einfluss auf die Ergebnisse hat. Falls die Informationen die Parameter des DGP unterschätzen, ist auch das Ergebnis zu klein, falls die die Parameter des DGP treffen ist das Ergebnis deutlich genauer als im Modell Log-Log bei identischer Parameterausprägung und falls die Informationen die Parameter überschätzen, werden auch die Schätzungen zu große Werte ergeben.

Modell	1	A	B	D
	2			
A		$\mu_0=0.5 \mu_{\text{real}}$ $\kappa_0=0.01$ $\sigma_0^2=0.5 \sigma_{\text{real}}$ $\nu_0=0.01$	$\mu_0=1.0 \mu_{\text{real}}$ $\kappa_0=0.01$ $\sigma_0^2=0.5 \sigma_{\text{real}}$ $\nu_0=0.01$	$\mu_0=1.5 \mu_{\text{real}}$ $\kappa_0=0.01$ $\sigma_0^2=0.5 \sigma_{\text{real}}$ $\nu_0=0.01$
B		$\mu_0=0.5 \mu_{\text{real}}$ $\kappa_0=0.01$ $\sigma_0^2=1.0 \sigma_{\text{real}}$ $\nu_0=0.01$	$\mu_0=1.0 \mu_{\text{real}}$ $\kappa_0=0.01$ $\sigma_0^2=1.0 \sigma_{\text{real}}$ $\nu_0=0.01$	$\mu_0=1.5 \mu_{\text{real}}$ $\kappa_0=0.01$ $\sigma_0^2=1.0 \sigma_{\text{real}}$ $\nu_0=0.01$
C		$\mu_0=0.5 \mu_{\text{real}}$ $\kappa_0=0.01$ $\sigma_0^2=1.5 \sigma_{\text{real}}$ $\nu_0=0.01$	$\mu_0=1.0 \mu_{\text{real}}$ $\kappa_0=0.01$ $\sigma_0^2=1.5 \sigma_{\text{real}}$ $\nu_0=0.01$	$\mu_0=1.5 \mu_{\text{real}}$ $\kappa_0=0.01$ $\sigma_0^2=1.5 \sigma_{\text{real}}$ $\nu_0=0.01$

Tabelle 6.33.: Kurzdarstellung der Modellspezifikation des Modells BayNiedrig. Das Modell basiert für die Schätzungen auf dem Modell Log–Log mit Parameterausprägung A1. Mit den Spalten variiert die A-Priori-Informationen über den Parameter μ , so dass dieser in Spalte A einen Wert annimmt der halb so groß ist, wie der reale Parameter des DGP, in Spalte B einen Wert, der dem Parameter μ des DGP entspricht und in Spalte C einen Wert, der 50% größer ist als der Parameter μ des DGP. Mit den Zeilen variiert die A-Priori-Information über den Parameter σ , so dass dieser wie schon der Parameter μ einen Wert annimmt der 50, 100 oder 150 Prozent des Parameters σ des DGP entspricht. Dabei wird die A-Priori-Information für die Parameter für sehr ungenau gehalten; die Parameter κ_0 und ν_0 nehmen einen Wert von 0.01 an.

6.4.2. Modell Bayes–niedriggewichtet

Die Grafiken zeigen die Ergebnisse unter der Annahme, dass die A-Priori-Informationen sehr niedrig gewichtet werden (Modell BayNiedrig). In Tabelle 6.33 wird zunächst die Modellspezifikation dargestellt. Dabei erhalten die Parameter κ_0 und ν_0 , die das Gewicht der A-Priori-Informationen festlegen den Wert 0.01, der zu einem geringen Gewicht dieser Informationen führt.

Bei der Darstellung der Ergebnisse zeigen sich im Wesentlichen die zu erwartenden




Abbildung 6.24.: Diese Grafik zeigt die Schwankungen des geschätzten OpVaR für das Modell BayNiedrig falls die A-Priori-Informationen die tatsächlichen Parameter des DGP jeweils um 50% unterschätzen. Der DGP entspricht dem DGP aus dem Modell Log-Log. Der tatsächliche OpVaR beträgt ca. 2 Mio. Für die Schätzung wird das in Kapitel 3.4 dargestellte Verfahren zur Berücksichtigung der A-Priori-Informationen genutzt. Es ist ersichtlich, dass die Verteilung des geschätzten OpVaR der aus Modell Log-Log ohne Berücksichtigung von A-Priori-Informationen sehr ähnlich ist. Die liegt darin begründet, dass die A-Priori-Informationen für sehr ungenau gehalten werden.

Resultate. Die A-Priori-Verteilungen der Parameter haben zwar einen gewissen Einfluss auf die Ergebnisse, so dass bei einer Unterschätzung auch die Schätzergebnisse den wahren Wert tendenziell unterschätzen und bei einer Überschätzung die Schätzergebnisse den wahren Wert tendenziell überschätzen. Dadurch, dass die Informationen jedoch für sehr ungenau gehalten werden, ist der Einfluss sowohl fehlerhafter als auch korrekter zusätzlicher Informationen auf das Gesamtergebnis relativ gering.




Abbildung 6.25.: Diese Grafik zeigt die Schwankungen des geschätzten OpVaR für das Modell BayNiedrig falls die A-Priori-Informationen die tatsächlichen Parameter des DGP genau ermitteln können. Der DGP entspricht dem DGP aus dem Modell Log-Log. Der tatsächliche OpVaR beträgt ca. 2 Mio. Für die Schätzung wird das in Kapitel 3.4 dargestellte Verfahren zur Berücksichtigung der A-Priori-Informationen genutzt. Es ist ersichtlich, dass die Verteilung des geschätzten OpVaR der aus Modell Log-Log ohne Berücksichtigung von A-Priori-Informationen sehr ähnlich ist. Die liegt darin begründet, dass die A-Priori-Informationen für sehr ungenau gehalten werden.




Abbildung 6.26.: Diese Grafik zeigt die Schwankungen des geschätzten OpVaR für das Modell BayNiedrig falls die A-Priori-Informationen die tatsächlichen Parameter des DGP um 50% überschätzen. Der DGP entspricht dem DGP aus dem Modell Log-Log. Der tatsächliche OpVaR beträgt ca. 2 Mio. Für die Schätzung wird das in Kapitel 3.4 dargestellte Verfahren zur Berücksichtigung der A-Priori-Informationen genutzt. Es ist ersichtlich, dass die Verteilung des geschätzten OpVaR der aus Modell Log-Log ohne Berücksichtigung von A-Priori-Informationen sehr ähnlich ist. Die liegt darin begründet, dass die A-Priori-Informationen für sehr ungenau gehalten werden.

Modell	1 2 Quantil	A		B		C	
		Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler
A	5%	702,576	70%	381,071	84%	1,145,066	51%
	95%	10,665,363	352%	8,271,631	251%	14,581,916	519%
B	5%	623,876	74%	354,855	85%	1,046,673	56%
	95%	11,267,449	378%	7,762,111	229%	14,916,689	533%
C	5%	628,895	73%	369,762	84%	942,341	60%
	95%	15,716,058	567%	9,784,655	315%	17,073,246	624%

Tabelle 6.34.: Übersicht über die Konfidenzintervalle und die relativen Fehler für den OpVaR für alle Parameterausprägungen für das Modell BayNiedrig. Die tatsächlichen OpVaR sind weiter oben in Tabelle 6.3 dargestellt. Es zeigt sich, dass unter der Annahme, dass die A-Priori-Informationen sehr ungenau sind der Prior lediglich einen relativ kleinen Einfluss auf die Ergebnisse hat.

6.5. Zusammenfassung der Ergebnisse

Die Resultate der Simulationen zeigen im Wesentlichen die erwarteten Ergebnisse. Bei den Modellen ohne Berücksichtigung von A-Priori-Informationen werden die Ergebnisse prinzipiell umso genauer, je mehr Daten für die Schätzung zur Verfügung stehen⁸. Weiterhin reduzieren sich die Schwankungen, wenn sich bei gleicher Anzahl erwarteter Verluste je Zeiteinheit die Schwankungen des einzelnen Verlusts reduzieren. Die tatsächliche Verteilung der Verlusthöhe gewinnt insbesondere an Bedeutung, falls die Schätzungen relativ genau werden. Dann kommt es vor, dass der tatsächliche OpVaR nicht einmal mehr innerhalb des bestimmten 90%-Quantils liegt; es kann also davon ausgegangen werden, dass keine konsistente Schätzung vorliegt. Dieser Effekt reduziert sich wieder beim Modell Log-Mis. Dabei gleichen sich die Überschätzungen und Unterschätzungen gegenseitig aus, so dass in Relation zu den übrigen Modellen mit Ausnahme des Modells Log-Log recht genaue Schätzungen möglich sind. Für den ES gelten für alle Modelle im Wesentlichen die gleichen Aussagen, wie für die Schätzungen des OpVaR.

Bei den Modellen unter Berücksichtigung von A-Priori-Informationen mit Hilfe eines bayesianischen Ansatz zeigt es sich, dass, falls die A-Priori-Informationen für sehr glaubwürdig gehalten werden, die Resultate stark von diesen Informationen beeinflusst werden. Unterschätzen diese den tatsächlichen OpVaR, dann wird durch die Simulation auch der geschätzte Wert kleiner sein als der tatsächliche, überschätzen sie ihn, dann ist auch der geschätzte Wert deutlich größer als der tatsächliche. Falls die A-Priori-Verteilung der tatsächlichen Verteilung im DGP entspricht, können die Schwankungen im Gegensatz zu den Modellen ohne zusätzliche Informationen reduziert werden. Die

⁸Die wenigen Ausnahmen resultieren im Wesentlichen daraus, dass aufgrund der Vielzahl der Simulationen lediglich 500 Schätzungen für die einzelnen Konfidenzintervalle ausreichen mussten. Gerade bei den Modellen 1–3, die durch große Schwankungen gekennzeichnet sind, ist es möglich, dass für eine Konvergenz deutlich mehr Iterationen notwendig sind.

Parameter wurden dabei grundsätzlich so gewählt, dass der Effekt deutlich hervortritt. Ähnliche Effekte, jedoch weniger ausgeprägt lassen sich erkennen, falls den A-Priori-Informationen ein kleineres Gewicht eingeräumt wird.

Die größte Genauigkeit der vorgestellten Modelle erzielt der Modelltyp Log–Log bei Modell D6. Dabei werden pro Jahr 250 Verluste mit einem Erwartungswert von jeweils 50.000 angenommen. Eine Anzahl, die in der Realität bei kaum einem Feld der Verlustmatrix auftreten dürfte. Dennoch schwankt der bestimmte OpVaR noch in einem Bereich von ca. 20%. Wenn man nun berücksichtigt, dass in den ersten Jahren der Anwendung eines AMA maximal Abweichungen nach unten von 5% von den Ergebnissen des Standardansatzes akzeptiert werden, wird deutlich, dass die bisher erreichte Genauigkeit der Schätzungen, selbst unter optimalen Rahmenbedingungen für eine industrielle Anwendung vermutlich nicht ausreichend ist und weitere Forschungen notwendig sind, um belastbare Aussagen über die Höhe eines OpVaR treffen zu können.

7. Schlussbetrachtung

Viele Autoren bezweifeln grundsätzlich die Sinnhaftigkeit einer quantitativen Analyse operationeller Risiken¹ und stellen die Behauptung auf, dass eine ausschließliche Beschäftigung mit der operativen Seite, mit der Verbesserung von Prozessen und Management, eine erfolgsversprechendere Variante sei.

Diesen Aussagen sei hiermit ausdrücklich widersprochen. Selbst wenn die Ergebnisse der vorliegenden Arbeit darauf hindeuten, dass aufgrund der geringen Datenbasis die Konfidenzintervalle sehr breit sind, ist es doch notwendig, diese zu kennen. Denn nur, wenn man um seine Unwissen oder auch die Ungenauigkeit seines Wissens weiß, ist man bestrebt, das fehlende Wissen zu erwerben. Durch rein qualitative Verfahren ist man als Vergleich entweder auf persönliche Einschätzungen oder auf einen Marktstandard angewiesen, der auf gleichen Verfahren beruht und relativ zu dem eine Einschätzung möglich ist. Die Information „wir sind besser als der Markt“ ist jedoch wertlos, wenn niemand weiß, welchem Risiko der Markt insgesamt zur Zeit ausgesetzt ist. Eine Verringerung des Risikos von Extremereignissen, die in 1.000 Jahren einmal erwartet werden, ist auf diese Weise nicht nachzuweisen. Dies kann ausschließlich mit quantitativen, statistisch fundierten Verfahren durchgeführt werden².

¹Stellvertretend für viele andere sei hier Ong (1998) genannt: „...quantify operational risk – what I like to think of as the blazing tail of the dinosaur comet.“ und: „I question the rationality of such faith in numbers.“

²und ist selbst mit diesen nahezu unmöglich

Weiterhin ist es für die Akzeptanz innerhalb des Unternehmens wichtig, dass auch der Bereich operationelle Risiken fundierte Zahlen liefern kann. Wenn Entscheidungen getroffen werden, sind für diese weiche Faktoren weniger relevant als harte Zahlen, die direkt in Kosten resultieren. Daher ist es notwendig, dass für operationelle Risiken geeignete Verfahren und Methoden zur Verfügung stehen. Möglicherweise müssen auch neue Messgrößen entwickelt werden, wenn sich herausstellen sollte, dass z.B. der OpVaR oder der ES nicht geeignet sein sollten, da wichtige spezifische Eigenschaften operationeller Risiken vernachlässigt werden.

Bisher wurde ein einfaches Modell verwendet und restriktive Forderungen an die Daten gestellt. Diese Forderungen³ könnten nach und nach aufgehoben werden.

Bei der Vorgabe der DGP sind unterschiedliche Veränderungen denkbar. Die wahren DGP könnten deutlich komplexer gestaltet werden, um so die Anforderungen an die Schätzungen zu erhöhen. Es ist möglich, weitere Verteilungen zu nutzen, Daten unterschiedlich zu modellieren sowie künstliche Ungenauigkeiten einzufügen, die in der Realität aus dem Prozess der Datensammlung oder aus Anreizen zum Verschleiern des Verlustes selbst, seiner Höhe oder der Verlustkategorie resultieren könnten.

Zusätzlich sind Forschungen in qualitativer Richtung notwendig, in denen untersucht wird, wie der Datensammlungsprozess optimiert werden kann und wie für Szenarioanalysen und Self-Assessments Anreize geschaffen werden können, um das Interesse, das eigene Risikokapital möglichst klein zu rechnen zu minimieren. Dabei könnten auch Wege zum Entstehen einer angemessenen Risikokultur untersucht werden.

Auf der anderen Seite können die Schätzmodelle selbst modifiziert werden. Zu erwähnen ist hier die Berücksichtigung weiterer Verteilungen oder auch der Kombination unterschiedlicher Verteilungen für die Schätzungen. Weiterhin könnten Abhängigkeiten

³vgl. Abschnitt 6.1 auf Seite 77

zwischen den einzelnen Daten, den Datenquellen, den Feldern der aus Risikokategorien und Geschäftsfeldern bestehenden Matrix oder auch innerhalb eines aus mehreren Unternehmen bestehenden Konzerns modelliert werden. Daneben könnten auch die Schätzverfahren selbst modifiziert werden. Bisher wurde die Bayes-Schätzung analytisch durchgeführt. Dies ist bei komplexeren Modellen nicht mehr möglich, hier würde dann die Nutzung eines Gibbs oder eines Metropolis-Hastings Algorithmus notwendig. Dies würde die Anforderungen an die Rechenleistung erneut deutlich erhöhen.

Schließlich könnte das für die Schätzungen genutzte Modell auch deutlich vom tatsächlichen DGP unterscheiden. Es ist zu vermuten, dass damit auch die Ergebnisse qualitativ schlechter werden, Überraschungen sind an dieser Stelle jedoch nicht auszuschließen. Eventuell kann man nachweisen, dass es ein relativ universelles Modell für Schätzungen gibt, dass bei unterschiedlichsten DGP hervorragende Ergebnisse liefert.

Für den tatsächlichen Einsatz der beschriebenen Modelle in der Praxis sind ebenfalls weitere Berechnungen notwendig. Bisher werden die Konfidenzintervalle unter der Bedingung bestimmt, dass der DGP bekannt ist. Damit kann bestimmt werden, wie genau die Schätzungen unter den gegebenen Annahmen und Einschränkungen im besten Fall werden können. Diese Informationen können genutzt werden, um eine grobe Schätzung über die Genauigkeit der Parameter zu erhalten. Mit Hilfe dieser Information kann dann entschieden werden, ob die Konfidenzintervalle ausreichend schmal sind, so dass nach einem zusätzlichen Risikoaufschlag das Risikokapital angemessen ermittelt werden konnte und der Bereich ausreichend vor anfallenden Kosten aus operationellen Risiken geschützt ist. Dies wird vermutlich dann vorkommen, wenn viele Verlustdaten vorliegen, wie es in den prozessorientierten Bereichen einer Bank der Fall sein dürfte. Ist dies nicht der Fall oder ist der Risikoaufschlag unangemessen hoch⁴, sind zusätzliche – über den quanti-

⁴Was in diesem Zusammenhang die Begriffe „ausreichend“ und „angemessen“ bedeuten, ist von der Führung des jeweiligen Instituts individuell festzulegen.

tativen Ansatz hinausgehende – Maßnahmen wie die direkte Einbeziehung des höheren Managements erforderlich.

Wenn in der Praxis ausschließlich die Daten zur Verfügung stehen, über den DGP selbst jedoch nichts weiter bekannt ist, ist es zusätzlich erforderlich zu bestimmen, wie groß die Konfidenzintervalle in diesem Fall werden. Dazu müssten nicht mehr, wie in dieser Arbeit durchgeführt, einzelne Parameterausprägungen simuliert werden, vielmehr müsste unter der Annahme eine Verteilung dieser Parameter der gesamte mögliche Wertebereich dieser Parameter simuliert werden, um anschließend die Verteilung der Parameter und damit der Konfidenzintervalle unter der Bedingung, dass ausschließlich die Daten bekannt sind, bestimmen zu können.

Es ist zu vermuten, dass für die Entwicklung des optimalen Modells zur Quantifizierung operationeller Risiken unter Berücksichtigung aller möglichen Einflüsse noch viel Forschungsarbeit zu leisten ist.

Anhang

A. Modell Lognormal-Lognormal

In diesem Abschnitt werden die Ergebnisse des Modells Lognormal-Lognormal detailliert aufgelistet. Zunächst werden die Tabellen aus Kapitel 6 wiederholt. Im Anschluss werden alle Grafiken zur Ermittlung der wahren 99.9%-Quantile und die Histogramme der MCS zu allen verschiedenen Parametern dargestellt.

Modell			A	B	C	D
	lambda	Erwartungswert	20,000	30,000	40,000	50,000
		99.9%-Quantil	1,000,000	1,000,000	1,000,000	1,000,000
		Anteil Datenverlust durch Threshold	69%	51%	35%	23%
1	5		1.5	2.5	3.2	3.8
2	10		3.1	4.9	6.5	7.7
3	25		7.7	12.3	16.2	19.2
4	50		15.5	24.7	32.4	38.4
5	100		30.9	49.4	64.9	76.9
6	250		77.3	123.5	162.2	192.2

Tabelle A.1.: Modellspezifikation Modelltyp LogLog

Modell	A	B	C	D
1	2.4	2.2	2.1	2.0
2	3.3	2.9	2.8	2.8
3	5.1	4.3	4.2	4.3
4	7.1	6.3	6.1	6.3
5	10.2	9.0	9.2	9.8
6	16.8	15.9	17.1	19.2

Tabelle A.2.: tatsächliche Werte VaR Modelltyp LogLog

Modell	A	B	C	D
1	4.0	3.4	2.9	2.7
2	5.4	4.3	3.8	3.6
3	8.2	6.2	5.4	5.3
4	10.9	8.5	7.6	7.4
5	14.9	11.7	11.0	11.1
6	22.8	19.0	19.1	20.7

Tabelle A.3.: tatsächliche Werte ES Modelltyp LogLog

Modell	Quantil	A		B		C		D	
		Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler
1	5%	157,265	93%	290,778	87%	412,629	80%	563,577	72%
	95%	15,670,006	566%	13,508,683	524%	12,601,149	506%	8,710,710	334%
2	5%	337,305	90%	606,242	79%	877,561	68%	1,092,125	60%
	95%	28,957,436	778%	24,650,012	754%	10,900,777	292%	8,222,833	198%
3	5%	983,174	81%	1,667,341	62%	2,153,160	49%	2,477,518	42%
	95%	26,222,045	410%	21,557,338	396%	11,626,534	176%	7,963,684	86%
4	5%	2,323,502	67%	3,164,347	49%	3,843,907	37%	4,423,339	30%
	95%	39,089,889	447%	13,560,594	116%	11,208,068	85%	9,990,079	58%
5	5%	4,271,842	58%	5,370,308	41%	6,679,512	28%	7,938,990	19%
	95%	36,624,385	260%	18,684,078	107%	12,967,831	40%	13,379,782	36%
6	5%	9,824,910	42%	11,929,889	25%	14,401,306	16%	17,031,779	11%
	95%	33,947,318	102%	22,252,593	40%	20,762,961	21%	22,211,164	16%

Tabelle A.4.: Übersicht über die relativen Fehler VaR, Modelltyp LogLog

Modell	Quantil	A		B		C		D	
		Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler
1	5%	178,852	95%	327,720	90%	480,678	83%	653,890	76%
	95%	48,447,475	1125%	35,261,881	950%	27,571,060	856%	15,290,471	468%
2	5%	381,952	93%	691,666	84%	1,018,984	73%	1,224,346	66%
	95%	86,555,455	1513%	60,896,492	1325%	18,749,790	389%	12,842,291	260%
3	5%	1,171,109	86%	1,967,135	68%	2,529,886	54%	2,795,704	47%
	95%	67,743,063	724%	45,692,076	637%	18,675,368	243%	10,881,190	107%
4	5%	2,832,274	74%	3,691,623	57%	4,359,578	42%	4,872,803	34%
	95%	95,039,080	769%	21,552,739	154%	16,040,468	112%	12,845,332	73%
5	5%	5,145,283	66%	6,245,114	46%	7,492,867	32%	8,686,505	22%
	95%	73,319,329	391%	27,635,581	137%	16,561,796	50%	16,139,444	46%
6	5%	12,218,481	46%	13,570,116	29%	15,579,896	19%	18,009,796	13%
	95%	54,379,623	139%	29,251,530	54%	24,611,867	29%	24,224,767	17%

Tabelle A.5.: Übersicht über die relativen Fehler ES, Modelltyp LogLog

Modell		A	B	C	D
Lognormal	μ	8.33 E+0	8.19 E+0	9.71 E+0	1.01 E+1
	σ	1.78 E+0	1.50 E+0	1.33 E+0	1.20 E+0

Tabelle A.6.: Parameter der Lognormalverteilung, Modelltyp LogLog

Spalte A, E=20.000

$\lambda = 8.33$, $\sigma = 1.78$ Der Erwartungswert eines Verlustes beträgt also 20.000. Das 99.9%-Quantil eines Verlustes beträgt 1.000.000.

Zeile 1, $\lambda=5$




Abbildung A.1.: Modell LogLog, Ergebnis A1, VaR, Wahrer Wert




Abbildung A.2.: Modell LogLog, Ergebnis A1, VaR




Abbildung A.3.: Modell LogLog, Ergebnis A1, ES, Wahrer Wert




Abbildung A.4.: Modell LogLog, Ergebnis A1, ES


Zeile 2, $\lambda=10$ 

Abbildung A.5.: Modell LogLog, Ergebnis A2, VaR, Wahrer Wert




Abbildung A.6.: Modell LogLog, Ergebnis A2, VaR




Abbildung A.7.: Modell LogLog, Ergebnis A2, ES, Wahrer Wert




Abbildung A.8.: Modell LogLog, Ergebnis A2, ES


Zeile 3, $\lambda=25$ 

Abbildung A.9.: Modell LogLog, Ergebnis A3, VaR, Wahrer Wert




Abbildung A.10.: Modell LogLog, Ergebnis A3, VaR




Abbildung A.11.: Modell LogLog, Ergebnis A3, ES, Wahrer Wert




Abbildung A.12.: Modell LogLog, Ergebnis A3, ES

Zeile 4, $\lambda=50$




Abbildung A.13.: Modell LogLog, Ergebnis A4, VaR, Wahrer Wert




Abbildung A.14.: Modell LogLog, Ergebnis A4, VaR




Abbildung A.15.: Modell LogLog, Ergebnis A4, ES, Wahrer Wert




Abbildung A.16.: Modell LogLog, Ergebnis A4, ES


Zeile 5, $\lambda=100$ 

Abbildung A.17.: Modell LogLog, Ergebnis A5, VaR, Wahrer Wert




Abbildung A.18.: Modell LogLog, Ergebnis A5, VaR




Abbildung A.19.: Modell LogLog, Ergebnis A5, ES, Wahrer Wert




Abbildung A.20.: Modell LogLog, Ergebnis A5, ES


Zeile 6, $\lambda=250$ 

Abbildung A.21.: Modell LogLog, Ergebnis A6, VaR, Wahrer Wert




Abbildung A.22.: Modell LogLog, Ergebnis A6, VaR




Abbildung A.23.: Modell LogLog, Ergebnis A6, ES, Wahrer Wert




Abbildung A.24.: Modell LogLog, Ergebnis A6, ES

Spalte B, E=30.000

$\lambda = 9.19$, $\sigma = 1.50$ Der Erwartungswert eines Verlustes beträgt also 30.000. Das 99.9%-Quantil eines Verlustes beträgt 1.000.000.

Zeile 1, $\lambda=5$




Abbildung A.25.: Modell LogLog, Ergebnis B1, VaR, Wahrer Wert




Abbildung A.26.: Modell LogLog, Ergebnis B1, VaR




Abbildung A.28.: Modell LogLog, Ergebnis B1, ES

Zeile 2, $\lambda=10$




Abbildung A.30.: Modell LogLog, Ergebnis B2, VaR




Abbildung A.32.: Modell LogLog, Ergebnis B2, ES

Zeile 3, $\lambda=25$




Abbildung A.33.: Modell LogLog, Ergebnis B3, VaR, Wahrer Wert




Abbildung A.34.: Modell LogLog, Ergebnis B3, VaR




Abbildung A.35.: Modell LogLog, Ergebnis B3, ES, Wahrer Wert




Abbildung A.36.: Modell LogLog, Ergebnis B3, ES

Zeile 4, $\lambda=50$




Abbildung A.37.: Modell LogLog, Ergebnis B4, VaR, Wahrer Wert




Abbildung A.38.: Modell LogLog, Ergebnis B4, VaR




Abbildung A.39.: Modell LogLog, Ergebnis B4, ES, Wahrer Wert




Abbildung A.40.: Modell LogLog, Ergebnis B4, ES

Zeile 5, $\lambda=100$




Abbildung A.41.: Modell LogLog, Ergebnis B5, VaR, Wahrer Wert




Abbildung A.42.: Modell LogLog, Ergebnis B5, VaR




Abbildung A.43.: Modell LogLog, Ergebnis B5, ES, Wahrer Wert




Abbildung A.44.: Modell LogLog, Ergebnis B5, ES

Zeile 6, $\lambda=250$




Abbildung A.45.: Modell LogLog, Ergebnis B6, VaR, Wahrer Wert




Abbildung A.46.: Modell LogLog, Ergebnis B6, VaR




Abbildung A.47.: Modell LogLog, Ergebnis B6, ES, Wahrer Wert




Abbildung A.48.: Modell LogLog, Ergebnis B6, ES

Spalte C, $E=40.000$

$\lambda = 9.72$, $\sigma = 1.33$ Der Erwartungswert eines Verlustes beträgt also 40.000. Das 99.9%-Quantil eines Verlustes beträgt 1.000.000.


Zeile 1, $\lambda=5$ 

Abbildung A.49.: Modell LogLog, Ergebnis C1, VaR, Wahrer Wert




Abbildung A.50.: Modell LogLog, Ergebnis C1, VaR




Abbildung A.51.: Modell LogLog, Ergebnis C1, ES, Wahrer Wert




Abbildung A.52.: Modell LogLog, Ergebnis C1, ES


Zeile 2, $\lambda=10$ 

Abbildung A.53.: Modell LogLog, Ergebnis C2, VaR, Wahrer Wert




Abbildung A.54.: Modell LogLog, Ergebnis C2, VaR




Abbildung A.55.: Modell LogLog, Ergebnis C2, ES, Wahrer Wert




Abbildung A.56.: Modell LogLog, Ergebnis C2, ES

Zeile 3, $\lambda=25$




Abbildung A.57.: Modell LogLog, Ergebnis C3, VaR, Wahrer Wert




Abbildung A.58.: Modell LogLog, Ergebnis C3, VaR




Abbildung A.59.: Modell LogLog, Ergebnis C3, ES, Wahrer Wert




Abbildung A.60.: Modell LogLog, Ergebnis C3, ES


Zeile 4, $\lambda=50$ 

Abbildung A.61.: Modell LogLog, Ergebnis C4, VaR, Wahrer Wert




Abbildung A.62.: Modell LogLog, Ergebnis C4, VaR




Abbildung A.63.: Modell LogLog, Ergebnis C4, ES, Wahrer Wert




Abbildung A.64.: Modell LogLog, Ergebnis C4, ES


Zeile 5, $\lambda=100$ 

Abbildung A.65.: Modell LogLog, Ergebnis C5, VaR, Wahrer Wert




Abbildung A.66.: Modell LogLog, Ergebnis C5, VaR




Abbildung A.67.: Modell LogLog, Ergebnis C5, ES, Wahrer Wert




Abbildung A.68.: Modell LogLog, Ergebnis C5, ES

Zeile 6, $\lambda=250$




Abbildung A.69.: Modell LogLog, Ergebnis C6, VaR, Wahrer Wert




Abbildung A.70.: Modell LogLog, Ergebnis C6, VaR




Abbildung A.71.: Modell LogLog, Ergebnis C6, ES, Wahrer Wert




Abbildung A.72.: Modell LogLog, Ergebnis C6, ES

Spalte D, E=50.000

$\lambda = 10.10$, $\sigma = 1.20$ Der Erwartungswert eines Verlustes beträgt also 50.000. Das 99.9%-Quantil eines Verlustes beträgt 1.000.000.

Zeile 1, $\lambda=5$




Abbildung A.73.: Modell LogLog, Ergebnis D1, VaR, Wahrer Wert




Abbildung A.74.: Modell LogLog, Ergebnis D1, VaR




Abbildung A.75.: Modell LogLog, Ergebnis D1, ES, Wahrer Wert




Abbildung A.76.: Modell LogLog, Ergebnis D1, ES

Zeile 2, $\lambda=10$




Abbildung A.77.: Modell LogLog, Ergebnis D2, VaR, Wahrer Wert




Abbildung A.78.: Modell LogLog, Ergebnis D2, VaR




Abbildung A.79.: Modell LogLog, Ergebnis D2, ES, Wahrer Wert




Abbildung A.80.: Modell LogLog, Ergebnis D2, ES

Zeile 3, $\lambda=25$




Abbildung A.81.: Modell LogLog, Ergebnis D3, VaR, Wahrer Wert




Abbildung A.82.: Modell LogLog, Ergebnis D3, VaR




Abbildung A.83.: Modell LogLog, Ergebnis D3, ES, Wahrer Wert




Abbildung A.84.: Modell LogLog, Ergebnis D3, ES

Zeile 4, $\lambda=50$




Abbildung A.85.: Modell LogLog, Ergebnis D4, VaR, Wahrer Wert




Abbildung A.86.: Modell LogLog, Ergebnis D4, VaR




Abbildung A.87.: Modell LogLog, Ergebnis D4, ES, Wahrer Wert




Abbildung A.88.: Modell LogLog, Ergebnis D4, ES

Zeile 5, $\lambda=100$




Abbildung A.89.: Modell LogLog, Ergebnis D5, VaR, Wahrer Wert




Abbildung A.90.: Modell LogLog, Ergebnis D5, VaR




Abbildung A.91.: Modell LogLog, Ergebnis D5, ES, Wahrer Wert




Abbildung A.92.: Modell LogLog, Ergebnis D5, ES

Zeile 6, $\lambda=250$




Abbildung A.93.: Modell LogLog, Ergebnis D6, VaR, Wahrer Wert




Abbildung A.94.: Modell LogLog, Ergebnis D6, VaR




Abbildung A.95.: Modell LogLog, Ergebnis D6, ES, Wahrer Wert




Abbildung A.96.: Modell LogLog, Ergebnis D6, ES

B. Modell Lognormal-Pareto

In diesem Abschnitt werden die Ergebnisse des Modells Lognormal-Pareto detailliert aufgelistet. Zunächst werden die Tabellen aus Kapitel 6 wiederholt. Im Anschluss werden alle Grafiken zur Ermittlung der wahren 99.9%-Quantile und die Histogramme der MCS zu allen verschiedenen Parametern dargestellt.

Modell			A	B	C	D
	lambda	Erwartungswert	20,000	30,000	40,000	50,000
		99.9%-Quantil	1,000,000	1,000,000	1,000,000	1,000,000
		Anteil Datenverlust durch Threshold	65%	45%	33%	26%
1	5		1.8	2.7	3.3	3.7
2	10		3.5	5.5	6.7	7.4
3	25		8.8	13.7	16.7	18.5
4	50		17.5	27.5	33.3	37.1
5	100		35.1	54.9	66.7	74.2
6	250		87.7	137.3	166.7	185.4

Tabelle B.1.: Modellspezifikation Modelltyp LogPar

Modell	A	B	C	D
1	3.2	2.6	2.3	2.2
2	4.8	3.8	3.2	3.1
3	9.1	6.4	5.2	4.9
4	14.9	9.6	7.9	7.2
5	24.5	14.7	11.9	11.2
6	45.7	26.5	21.9	21.4

Tabelle B.2.: tatsächliche Werte VaR Modelltyp LogPar

Modell	A	B	C	D
1	9.1	5.2	3.9	3.3
2	13.3	7.8	5.6	4.6
3	25.2	13.3	8.6	7.1
4	41.7	18.0	12.3	10.0
5	65.1	26.8	17.9	14.6
6	121.2	46.7	30.6	26.0

Tabelle B.3.: tatsächliche Werte ES Modelltyp LogPar

Modell	Quantil	A Wert	Rel. Fehler	B Wert	Rel. Fehler	C Wert	Rel. Fehler	D Wert	Rel. Fehler
1	5%	152,956	95%	257,505	90%	426,370	82%	558,841	74%
	95%	9,260,657	193%	9,827,171	276%	10,286,770	346%	6,151,237	181%
2	5%	296,939	94%	567,048	85%	856,872	74%	1,127,337	63%
	95%	17,421,353	262%	14,239,741	275%	9,111,728	181%	8,246,766	169%
3	5%	805,350	91%	1,373,831	79%	1,971,190	62%	2,418,150	51%
	95%	23,858,284	161%	10,751,817	67%	7,078,449	35%	7,378,112	50%
4	5%	1,739,993	88%	2,573,944	73%	3,448,600	56%	4,274,337	41%
	95%	27,326,611	83%	9,477,634	-1%	8,330,712	6%	8,191,203	14%
5	5%	3,508,693	86%	4,741,687	68%	6,197,612	48%	7,437,723	34%
	95%	31,541,003	28%	12,049,824	-18%	10,481,086	-12%	11,401,568	1%
6	5%	8,093,122	82%	10,352,903	61%	13,275,541	39%	16,537,179	23%
	95%	35,204,125	-23%	16,893,543	-36%	17,877,827	-18%	20,534,580	-4%

Tabelle B.4.: Übersicht über die relativen Fehler VaR, Modelltyp LogPar

Modell	Quantil	A Wert	Rel. Fehler	B Wert	Rel. Fehler	C Wert	Rel. Fehler	D Wert	Rel. Fehler
1	5%	167,445	98%	286,422	95%	483,581	88%	641,707	81%
	95%	25,964,483	185%	26,864,481	413%	21,572,715	454%	9,687,906	190%
2	5%	324,616	98%	640,290	92%	966,937	83%	1,302,208	72%
	95%	48,131,028	262%	30,315,772	291%	15,308,713	174%	12,719,370	178%
3	5%	907,769	96%	1,560,159	88%	2,147,045	75%	2,715,332	62%
	95%	61,280,290	144%	18,245,702	37%	9,926,784	16%	9,827,955	38%
4	5%	2,079,049	95%	2,824,973	84%	3,839,565	69%	4,726,217	53%
	95%	63,313,896	52%	13,556,312	-25%	10,933,057	-11%	9,934,160	0%
5	5%	4,160,576	94%	5,251,229	80%	6,744,373	62%	8,015,491	45%
	95%	64,920,633	0%	16,464,498	-39%	12,490,091	-30%	12,995,362	-11%
6	5%	9,481,504	92%	11,247,965	76%	13,977,687	54%	17,380,551	33%
	95%	60,628,860	-50%	20,224,070	-57%	19,766,037	-35%	22,069,098	-15%

Tabelle B.5.: Übersicht über die relativen Fehler ES, Modelltyp LogPar

Modell		A	B	C	D
Pareto	α	1.49 E+0	1.90 E+0	2.29 E+0	2.73 E+0
	0	9.82 E+3	2.69 E+4	5.17 E+4	8.64 E+4

Tabelle B.6.: Parameter der Lognormalverteilung, Modelltyp LogPar

Spalte A, E=20.000

$\lambda = 8.33$, $\sigma = 1.78$ Der Erwartungswert eines Verlustes beträgt also 20.000. Das 99.9%-Quantil eines Verlustes beträgt 1.000.000.

Zeile 1, $\lambda=5$




Abbildung B.1.: Modell LogPar, Ergebnis A1, VaR, Wahrer Wert




Abbildung B.2.: Modell LogPar, Ergebnis A1, VaR




Abbildung B.3.: Modell LogPar, Ergebnis A1, ES, Wahrer Wert




Abbildung B.4.: Modell LogPar, Ergebnis A1, ES

Zeile 2, $\lambda=10$




Abbildung B.5.: Modell LogPar, Ergebnis A2, VaR, Wahrer Wert




Abbildung B.6.: Modell LogPar, Ergebnis A2, VaR




Abbildung B.7.: Modell LogPar, Ergebnis A2, ES, Wahrer Wert




Abbildung B.8.: Modell LogPar, Ergebnis A2, ES

Zeile 3, $\lambda=25$




Abbildung B.9.: Modell LogPar, Ergebnis A3, VaR, Wahrer Wert




Abbildung B.10.: Modell LogPar, Ergebnis A3, VaR




Abbildung B.11.: Modell LogPar, Ergebnis A3, ES, Wahrer Wert




Abbildung B.12.: Modell LogPar, Ergebnis A3, ES

Zeile 4, $\lambda=50$




Abbildung B.13.: Modell LogPar, Ergebnis A4, VaR, Wahrer Wert




Abbildung B.14.: Modell LogPar, Ergebnis A4, VaR




Abbildung B.15.: Modell LogPar, Ergebnis A4, ES, Wahrer Wert




Abbildung B.16.: Modell LogPar, Ergebnis A4, ES

Zeile 5, $\lambda=100$




Abbildung B.17.: Modell LogPar, Ergebnis A5, VaR, Wahrer Wert




Abbildung B.18.: Modell LogPar, Ergebnis A5, VaR




Abbildung B.19.: Modell LogPar, Ergebnis A5, ES, Wahrer Wert




Abbildung B.20.: Modell LogPar, Ergebnis A5, ES

Zeile 6, $\lambda=250$




Abbildung B.21.: Modell LogPar, Ergebnis A6, VaR, Wahrer Wert




Abbildung B.22.: Modell LogPar, Ergebnis A6, VaR




Abbildung B.23.: Modell LogPar, Ergebnis A6, ES, Wahrer Wert




Abbildung B.24.: Modell LogPar, Ergebnis A6, ES

Spalte B, E=30.000

$\lambda = 9.19$, $\sigma = 1.50$ Der Erwartungswert eines Verlustes beträgt also 30.000. Das 99.9%-Quantil eines Verlustes beträgt 1.000.000.

Zeile 1, $\lambda=5$




Abbildung B.25.: Modell LogPar, Ergebnis B1, VaR, Wahrer Wert




Abbildung B.26.: Modell LogPar, Ergebnis B1, VaR




Abbildung B.27.: Modell LogPar, Ergebnis B1, ES, Wahrer Wert




Abbildung B.28.: Modell LogPar, Ergebnis B1, ES


Zeile 2, $\lambda=10$ 

Abbildung B.29.: Modell LogPar, Ergebnis B2, VaR, Wahrer Wert




Abbildung B.30.: Modell LogPar, Ergebnis B2, VaR




Abbildung B.31.: Modell LogPar, Ergebnis B2, ES, Wahrer Wert




Abbildung B.32.: Modell LogPar, Ergebnis B2, ES


Zeile 3, $\lambda=25$ 

Abbildung B.33.: Modell LogPar, Ergebnis B3, VaR, Wahrer Wert




Abbildung B.34.: Modell LogPar, Ergebnis B3, VaR




Abbildung B.35.: Modell LogPar, Ergebnis B3, ES, Wahrer Wert




Abbildung B.36.: Modell LogPar, Ergebnis B3, ES

Zeile 4, $\lambda=50$




Abbildung B.37.: Modell LogPar, Ergebnis B4, VaR, Wahrer Wert




Abbildung B.38.: Modell LogPar, Ergebnis B4, VaR




Abbildung B.39.: Modell LogPar, Ergebnis B4, ES, Wahrer Wert




Abbildung B.40.: Modell LogPar, Ergebnis B4, ES


Zeile 5, $\lambda=100$ 

Abbildung B.41.: Modell LogPar, Ergebnis B5, VaR, Wahrer Wert




Abbildung B.42.: Modell LogPar, Ergebnis B5, VaR




Abbildung B.43.: Modell LogPar, Ergebnis B5, ES, Wahrer Wert




Abbildung B.44.: Modell LogPar, Ergebnis B5, ES


Zeile 6, $\lambda=250$ 

Abbildung B.45.: Modell LogPar, Ergebnis B6, VaR, Wahrer Wert




Abbildung B.46.: Modell LogPar, Ergebnis B6, VaR




Abbildung B.47.: Modell LogPar, Ergebnis B6, ES, Wahrer Wert




Abbildung B.48.: Modell LogPar, Ergebnis B6, ES

Spalte C, E=40.000

$\lambda = 9.72$, $\sigma = 1.33$ Der Erwartungswert eines Verlustes beträgt also 40.000. Das 99.9%-Quantil eines Verlustes beträgt 1.000.000.

Zeile 1, $\lambda=5$




Abbildung B.49.: Modell LogPar, Ergebnis C1, VaR, Wahrer Wert




Abbildung B.50.: Modell LogPar, Ergebnis C1, VaR




Abbildung B.51.: Modell LogPar, Ergebnis C1, ES, Wahrer Wert




Abbildung B.52.: Modell LogPar, Ergebnis C1, ES

Zeile 2, $\lambda=10$




Abbildung B.53.: Modell LogPar, Ergebnis C2, VaR, Wahrer Wert




Abbildung B.54.: Modell LogPar, Ergebnis C2, VaR




Abbildung B.55.: Modell LogPar, Ergebnis C2, ES, Wahrer Wert




Abbildung B.56.: Modell LogPar, Ergebnis C2, ES

Zeile 3, $\lambda=25$




Abbildung B.57.: Modell LogPar, Ergebnis C3, VaR, Wahrer Wert




Abbildung B.58.: Modell LogPar, Ergebnis C3, VaR




Abbildung B.59.: Modell LogPar, Ergebnis C3, ES, Wahrer Wert




Abbildung B.60.: Modell LogPar, Ergebnis C3, ES

Zeile 4, $\lambda=50$




Abbildung B.61.: Modell LogPar, Ergebnis C4, VaR, Wahrer Wert




Abbildung B.62.: Modell LogPar, Ergebnis C4, VaR




Abbildung B.63.: Modell LogPar, Ergebnis C4, ES, Wahrer Wert




Abbildung B.64.: Modell LogPar, Ergebnis C4, ES

Zeile 5, $\lambda=100$




Abbildung B.65.: Modell LogPar, Ergebnis C5, VaR, Wahrer Wert




Abbildung B.66.: Modell LogPar, Ergebnis C5, VaR




Abbildung B.67.: Modell LogPar, Ergebnis C5, ES, Wahrer Wert




Abbildung B.68.: Modell LogPar, Ergebnis C5, ES

Zeile 6, $\lambda=250$




Abbildung B.69.: Modell LogPar, Ergebnis C6, VaR, Wahrer Wert




Abbildung B.70.: Modell LogPar, Ergebnis C6, VaR




Abbildung B.71.: Modell LogPar, Ergebnis C6, ES, Wahrer Wert




Abbildung B.72.: Modell LogPar, Ergebnis C6, ES

Spalte D, $E=50.000$

$\lambda = 10.10$, $\sigma = 1.20$ Der Erwartungswert eines Verlustes beträgt also 50.000. Das 99.9%-Quantil eines Verlustes beträgt 1.000.000.


Zeile 1, $\lambda=5$ 

Abbildung B.73.: Modell LogPar, Ergebnis D1, VaR, Wahrer Wert




Abbildung B.74.: Modell LogPar, Ergebnis D1, VaR




Abbildung B.75.: Modell LogPar, Ergebnis D1, ES, Wahrer Wert




Abbildung B.76.: Modell LogPar, Ergebnis D1, ES


Zeile 2, $\lambda=10$ 

Abbildung B.77.: Modell LogPar, Ergebnis D2, VaR, Wahrer Wert




Abbildung B.78.: Modell LogPar, Ergebnis D2, VaR




Abbildung B.79.: Modell LogPar, Ergebnis D2, ES, Wahrer Wert




Abbildung B.80.: Modell LogPar, Ergebnis D2, ES

Zeile 3, $\lambda=25$




Abbildung B.81.: Modell LogPar, Ergebnis D3, VaR, Wahrer Wert




Abbildung B.82.: Modell LogPar, Ergebnis D3, VaR




Abbildung B.83.: Modell LogPar, Ergebnis D3, ES, Wahrer Wert




Abbildung B.84.: Modell LogPar, Ergebnis D3, ES


Zeile 4, $\lambda=50$ 

Abbildung B.85.: Modell LogPar, Ergebnis D4, VaR, Wahrer Wert




Abbildung B.86.: Modell LogPar, Ergebnis D4, VaR




Abbildung B.87.: Modell LogPar, Ergebnis D4, ES, Wahrer Wert




Abbildung B.88.: Modell LogPar, Ergebnis D4, ES


Zeile 5, $\lambda=100$ 

Abbildung B.89.: Modell LogPar, Ergebnis D5, VaR, Wahrer Wert




Abbildung B.90.: Modell LogPar, Ergebnis D5, VaR




Abbildung B.91.: Modell LogPar, Ergebnis D5, ES, Wahrer Wert
Zeile 6, $\lambda=250$




Abbildung B.92.: Modell LogPar, Ergebnis D5, ES




Abbildung B.93.: Modell LogPar, Ergebnis D6, VaR, Wahrer Wert




Abbildung B.94.: Modell LogPar, Ergebnis D6, VaR




Abbildung B.95.: Modell LogPar, Ergebnis D6, ES, Wahrer Wert




Abbildung B.96.: Modell LogPar, Ergebnis D6, ES

C. Modell Lognormal-Weibull

In diesem Abschnitt werden die Ergebnisse des Modells Lognormal-Weibull detailliert aufgelistet. Zunächst werden die Tabellen aus Kapitel 6 wiederholt. Im Anschluss werden alle Grafiken zur Ermittlung der wahren 99.9%-Quantile und die Histogramme der MCS zu allen verschiedenen Parametern dargestellt.

Modell			A	B	C	D
	lambda	Erwartungswert	20,000	30,000	40,000	50,000
		99.9%-Quantil	1,000,000	1,000,000	1,000,000	1,000,000
		Anteil Datenverlust durch Threshold	75%	62%	52%	43%
1	5		1.3	1.9	2.4	2.9
2	10		2.5	3.8	4.8	5.7
3	25		6.3	9.4	12.1	14.3
4	50		12.5	18.8	24.1	28.6
5	100		25.0	37.6	48.3	57.2
6	250		62.5	94.1	120.7	143.0

Tabelle C.1.: Modellspezifikation Modelltyp LogWei

Modell	A	B	C	D
1	2.0	1.9	1.8	1.8
2	2.5	2.4	2.4	2.5
3	3.6	3.5	3.6	3.8
4	4.8	4.8	5.3	5.8
5	6.8	7.2	8.2	9.3
6	11.4	13.3	15.9	18.8

Tabelle C.2.: tatsächliche Werte VaR Modelltyp LogWei

Modell	A	B	C	D
1	2.7	2.4	2.2	2.2
2	3.4	3.0	2.8	2.8
3	4.7	4.1	4.1	4.3
4	6.0	5.6	5.8	6.3
5	8.0	8.0	8.8	9.9
6	12.9	14.3	16.7	19.5

Tabelle C.3.: tatsächliche Werte ES Modelltyp LogWei

Modell	Quantil	A Wert	Rel. Fehler	B Wert	Rel. Fehler	C Wert	Rel. Fehler	D Wert	Rel. Fehler
1	5%	215,419	89%	317,112	83%	471,375	74%	553,546	70%
	95%	34,787,958	1681%	17,644,658	851%	17,543,594	861%	16,098,990	772%
2	5%	503,844	80%	753,437	68%	986,266	58%	1,465,628	40%
	95%	22,268,101	779%	32,042,619	1248%	21,563,028	809%	15,364,668	526%
3	5%	1,306,662	64%	1,980,537	43%	2,682,682	26%	3,143,704	18%
	95%	34,812,312	865%	17,842,975	415%	14,718,800	306%	14,234,759	271%
4	5%	2,645,795	45%	3,764,273	22%	4,677,698	11%	5,626,804	3%
	95%	28,541,019	489%	18,687,938	285%	16,394,323	212%	14,115,352	143%
5	5%	5,235,490	23%	6,653,676	8%	8,042,755	2%	9,729,573	-5%
	95%	28,184,105	316%	21,064,661	192%	18,287,557	123%	18,779,935	102%
6	5%	10,777,800	6%	14,151,825	-6%	17,205,973	-8%	20,254,931	-8%
	95%	31,720,124	178%	27,436,340	106%	27,468,352	72%	28,998,869	54%

Tabelle C.4.: Übersicht über die relativen Fehler VaR, Modelltyp LogWei

Modell	Quantil	A Wert	Rel. Fehler	B Wert	Rel. Fehler	C Wert	Rel. Fehler	D Wert	Rel. Fehler
1	5%	250,512	91%	374,340	84%	545,230	76%	669,285	70%
	95%	118,503,393	4216%	47,300,638	1874%	36,264,800	1524%	32,500,531	1372%
2	5%	610,162	82%	938,514	68%	1,169,432	59%	1,734,288	39%
	95%	58,983,619	1629%	81,787,171	2655%	42,886,585	1406%	28,370,119	896%
3	5%	1,611,833	65%	2,401,887	42%	3,252,313	21%	3,692,903	14%
	95%	85,908,529	1746%	34,975,290	748%	22,544,588	445%	21,669,559	407%
4	5%	3,213,452	47%	4,489,920	20%	5,508,744	5%	6,540,645	-4%
	95%	51,463,443	755%	30,390,386	441%	24,747,088	326%	19,596,620	212%
5	5%	6,625,057	18%	8,032,917	0%	9,415,830	-7%	11,162,804	-13%
	95%	47,592,086	492%	30,925,948	286%	24,946,419	184%	24,292,396	146%
6	5%	13,249,553	-3%	16,709,249	-17%	19,413,000	-16%	22,357,307	-15%
	95%	46,843,600	263%	37,368,435	162%	34,087,212	104%	33,854,797	74%

Tabelle C.5.: Übersicht über die relativen Fehler ES, Modelltyp LogWei

Modell		A	B	C	D
Weibull	τ	3.49 E-1	4.25 E-1	4.89 E-1	5.46 E-1
	θ	3.94 E+3	1.06 E+4	1.91 E+4	2.91 E+4

Tabelle C.6.: Parameter der Lognormalverteilung, Modelltyp LogWei

Spalte A, E=20.000

$\lambda = 8.33$, $\sigma = 1.78$ Der Erwartungswert eines Verlustes beträgt also 20.000. Das 99.9%-Quantil eines Verlustes beträgt 1.000.000.

Zeile 1, $\lambda=5$




Abbildung C.1.: Modell LogWei, Ergebnis A1, VaR, Wahrer Wert




Abbildung C.2.: Modell LogWei, Ergebnis A1, VaR




Abbildung C.3.: Modell LogWei, Ergebnis A1, ES, Wahrer Wert




Abbildung C.4.: Modell LogWei, Ergebnis A1, ES

Zeile 2, $\lambda=10$




Abbildung C.5.: Modell LogWei, Ergebnis A2, VaR, Wahrer Wert




Abbildung C.6.: Modell LogWei, Ergebnis A2, VaR




Abbildung C.7.: Modell LogWei, Ergebnis A2, ES, Wahrer Wert




Abbildung C.8.: Modell LogWei, Ergebnis A2, ES

Zeile 3, $\lambda=25$




Abbildung C.9.: Modell LogWei, Ergebnis A3, VaR, Wahrer Wert




Abbildung C.10.: Modell LogWei, Ergebnis A3, VaR




Abbildung C.11.: Modell LogWei, Ergebnis A3, ES, Wahrer Wert




Abbildung C.12.: Modell LogWei, Ergebnis A3, ES

Zeile 4, $\lambda=50$




Abbildung C.13.: Modell LogWei, Ergebnis A4, VaR, Wahrer Wert




Abbildung C.14.: Modell LogWei, Ergebnis A4, VaR




Abbildung C.15.: Modell LogWei, Ergebnis A4, ES, Wahrer Wert




Abbildung C.16.: Modell LogWei, Ergebnis A4, ES

Zeile 5, $\lambda=100$




Abbildung C.17.: Modell LogWei, Ergebnis A5, VaR, Wahrer Wert




Abbildung C.18.: Modell LogWei, Ergebnis A5, VaR




Abbildung C.19.: Modell LogWei, Ergebnis A5, ES, Wahrer Wert




Abbildung C.20.: Modell LogWei, Ergebnis A5, ES

Zeile 6, $\lambda=250$




Abbildung C.21.: Modell LogWei, Ergebnis A6, VaR, Wahrer Wert




Abbildung C.22.: Modell LogWei, Ergebnis A6, VaR




Abbildung C.23.: Modell LogWei, Ergebnis A6, ES, Wahrer Wert




Abbildung C.24.: Modell LogWei, Ergebnis A6, ES

Spalte B, E=30.000

$\lambda = 9.19$, $\sigma = 1.50$ Der Erwartungswert eines Verlustes beträgt also 30.000. Das 99.9%-Quantil eines Verlustes beträgt 1.000.000.

Zeile 1, $\lambda=5$




Abbildung C.25.: Modell LogWei, Ergebnis B1, VaR, Wahrer Wert




Abbildung C.26.: Modell LogWei, Ergebnis B1, VaR




Abbildung C.27.: Modell LogWei, Ergebnis B1, ES, Wahrer Wert




Abbildung C.28.: Modell LogWei, Ergebnis B1, ES


Zeile 2, $\lambda=10$ 

Abbildung C.29.: Modell LogWei, Ergebnis B2, VaR, Wahrer Wert




Abbildung C.30.: Modell LogWei, Ergebnis B2, VaR




Abbildung C.31.: Modell LogWei, Ergebnis B2, ES, Wahrer Wert




Abbildung C.32.: Modell LogWei, Ergebnis B2, ES


Zeile 3, $\lambda=25$ 

Abbildung C.33.: Modell LogWei, Ergebnis B3, VaR, Wahrer Wert




Abbildung C.34.: Modell LogWei, Ergebnis B3, VaR




Abbildung C.35.: Modell LogWei, Ergebnis B3, ES, Wahrer Wert




Abbildung C.36.: Modell LogWei, Ergebnis B3, ES

Zeile 4, $\lambda=50$




Abbildung C.37.: Modell LogWei, Ergebnis B4, VaR, Wahrer Wert




Abbildung C.38.: Modell LogWei, Ergebnis B4, VaR




Abbildung C.39.: Modell LogWei, Ergebnis B4, ES, Wahrer Wert




Abbildung C.40.: Modell LogWei, Ergebnis B4, ES


Zeile 5, $\lambda=100$ 

Abbildung C.41.: Modell LogWei, Ergebnis B5, VaR, Wahrer Wert




Abbildung C.42.: Modell LogWei, Ergebnis B5, VaR




Abbildung C.43.: Modell LogWei, Ergebnis B5, ES, Wahrer Wert




Abbildung C.44.: Modell LogWei, Ergebnis B5, ES


Zeile 6, $\lambda=250$ 

Abbildung C.45.: Modell LogWei, Ergebnis B6, VaR, Wahrer Wert




Abbildung C.46.: Modell LogWei, Ergebnis B6, VaR




Abbildung C.47.: Modell LogWei, Ergebnis B6, ES, Wahrer Wert




Abbildung C.48.: Modell LogWei, Ergebnis B6, ES

Spalte C, E=40.000

$\lambda = 9.72$, $\sigma = 1.33$ Der Erwartungswert eines Verlustes beträgt also 40.000. Das 99.9%-Quantil eines Verlustes beträgt 1.000.000.

Zeile 1, $\lambda=5$




Abbildung C.49.: Modell LogWei, Ergebnis C1, VaR, Wahrer Wert




Abbildung C.50.: Modell LogWei, Ergebnis C1, VaR




Abbildung C.51.: Modell LogWei, Ergebnis C1, ES, Wahrer Wert




Abbildung C.52.: Modell LogWei, Ergebnis C1, ES

Zeile 2, $\lambda=10$




Abbildung C.53.: Modell LogWei, Ergebnis C2, VaR, Wahrer Wert




Abbildung C.54.: Modell LogWei, Ergebnis C2, VaR




Abbildung C.55.: Modell LogWei, Ergebnis C2, ES, Wahrer Wert




Abbildung C.56.: Modell LogWei, Ergebnis C2, ES

Zeile 3, $\lambda=25$




Abbildung C.57.: Modell LogWei, Ergebnis C3, VaR, Wahrer Wert




Abbildung C.58.: Modell LogWei, Ergebnis C3, VaR




Abbildung C.59.: Modell LogWei, Ergebnis C3, ES, Wahrer Wert




Abbildung C.60.: Modell LogWei, Ergebnis C3, ES

Zeile 4, $\lambda=50$




Abbildung C.61.: Modell LogWei, Ergebnis C4, VaR, Wahrer Wert




Abbildung C.62.: Modell LogWei, Ergebnis C4, VaR




Abbildung C.63.: Modell LogWei, Ergebnis C4, ES, Wahrer Wert




Abbildung C.64.: Modell LogWei, Ergebnis C4, ES

Zeile 5, $\lambda=100$




Abbildung C.65.: Modell LogWei, Ergebnis C5, VaR, Wahrer Wert




Abbildung C.66.: Modell LogWei, Ergebnis C5, VaR




Abbildung C.67.: Modell LogWei, Ergebnis C5, ES, Wahrer Wert




Abbildung C.68.: Modell LogWei, Ergebnis C5, ES

Zeile 6, $\lambda=250$




Abbildung C.69.: Modell LogWei, Ergebnis C6, VaR, Wahrer Wert




Abbildung C.70.: Modell LogWei, Ergebnis C6, VaR




Abbildung C.71.: Modell LogWei, Ergebnis C6, ES, Wahrer Wert




Abbildung C.72.: Modell LogWei, Ergebnis C6, ES

Spalte D, E=50.000

$\lambda = 10.10$, $\sigma = 1.20$ Der Erwartungswert eines Verlustes beträgt also 50.000. Das 99.9%-Quantil eines Verlustes beträgt 1.000.000.


Zeile 1, $\lambda=5$ 

Abbildung C.73.: Modell LogWei, Ergebnis D1, VaR, Wahrer Wert




Abbildung C.74.: Modell LogWei, Ergebnis D1, VaR




Abbildung C.75.: Modell LogWei, Ergebnis D1, ES, Wahrer Wert




Abbildung C.76.: Modell LogWei, Ergebnis D1, ES


Zeile 2, $\lambda=10$ 

Abbildung C.77.: Modell LogWei, Ergebnis D2, VaR, Wahrer Wert




Abbildung C.78.: Modell LogWei, Ergebnis D2, VaR




Abbildung C.79.: Modell LogWei, Ergebnis D2, ES, Wahrer Wert




Abbildung C.80.: Modell LogWei, Ergebnis D2, ES

Zeile 3, $\lambda=25$




Abbildung C.81.: Modell LogWei, Ergebnis D3, VaR, Wahrer Wert




Abbildung C.82.: Modell LogWei, Ergebnis D3, VaR




Abbildung C.83.: Modell LogWei, Ergebnis D3, ES, Wahrer Wert




Abbildung C.84.: Modell LogWei, Ergebnis D3, ES


Zeile 4, $\lambda=50$ 

Abbildung C.85.: Modell LogWei, Ergebnis D4, VaR, Wahrer Wert




Abbildung C.86.: Modell LogWei, Ergebnis D4, VaR




Abbildung C.87.: Modell LogWei, Ergebnis D4, ES, Wahrer Wert




Abbildung C.88.: Modell LogWei, Ergebnis D4, ES


Zeile 5, $\lambda=100$ 

Abbildung C.89.: Modell LogWei, Ergebnis D5, VaR, Wahrer Wert




Abbildung C.90.: Modell LogWei, Ergebnis D5, VaR




Abbildung C.91.: Modell LogWei, Ergebnis D5, ES, Wahrer Wert
Zeile 6, $\lambda=250$




Abbildung C.92.: Modell LogWei, Ergebnis D5, ES




Abbildung C.93.: Modell LogWei, Ergebnis D6, VaR, Wahrer Wert




Abbildung C.94.: Modell LogWei, Ergebnis D6, VaR




Abbildung C.95.: Modell LogWei, Ergebnis D6, ES, Wahrer Wert




Abbildung C.96.: Modell LogWei, Ergebnis D6, ES

D. Modell Lognormal-Gamma

In diesem Abschnitt werden die Ergebnisse des Modells Lognormal-Gamma detailliert aufgelistet. Zunächst werden die Tabellen aus Kapitel 6 wiederholt. Im Anschluss werden alle Grafiken zur Ermittlung der wahren 99.9%-Quantile und die Histogramme der MCS zu allen verschiedenen Parametern dargestellt.

Modell			A	B	C	D
	lambda	Erwartungswert	20,000	30,000	40,000	50,000
		99.9%-Quantil	1,000,000	1,000,000	1,000,000	1,000,000
		Anteil Datenverlust durch Threshold	84%	74%	65%	56%
1	5		0.8	1.3	1.8	2.2
2	10		1.6	2.6	3.5	4.4
3	25		4.0	6.4	8.8	11.0
4	50		8.0	12.8	17.5	22.0
5	100		16.0	25.6	35.0	44.0
6	250		39.9	63.9	87.6	109.9

Tabelle D.1.: Modellspezifikation Modelltyp LogGam

Modell	A	B	C	D
1	1.7	1.7	1.8	1.8
2	2.0	2.1	2.3	2.4
3	2.9	3.2	3.5	3.9
4	3.9	4.5	5.2	5.9
5	5.7	7.0	8.2	9.5
6	10.2	13.2	16.2	19.2

Tabelle D.2.: tatsächliche Werte VaR Modelltyp LogGam

Modell	A	B	C	D
1	2.0	2.0	2.0	2.1
2	2.4	2.4	2.5	2.7
3	3.2	3.5	3.9	4.2
4	4.3	4.9	5.6	6.3
5	6.2	7.4	8.7	10.0
6	10.9	13.9	16.8	19.9

Tabelle D.3.: tatsächliche Werte ES Modelltyp LogGam

Modell	Quantil	A		B		C		D	
		Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler
1	5%	374,601	77%	405,785	76%	530,599	70%	730,907	60%
	95%	26,996,242	1531%	20,410,930	1114%	26,453,419	1410%	14,919,698	721%
2	5%	474,977	77%	843,262	60%	1,121,134	50%	1,553,675	36%
	95%	55,778,974	2649%	27,580,001	1193%	23,874,355	959%	18,442,756	664%
3	5%	1,891,593	34%	2,789,018	12%	3,496,986	1%	4,057,581	-5%
	95%	31,081,193	989%	23,039,611	629%	19,705,252	458%	17,595,689	355%
4	5%	3,910,565	0%	4,668,916	-3%	5,988,630	-15%	7,254,301	-23%
	95%	29,187,157	645%	26,929,952	494%	20,050,129	284%	20,247,810	243%
5	5%	6,844,813	-20%	9,170,466	-32%	10,821,208	-32%	11,868,798	-25%
	95%	30,703,678	439%	26,229,669	277%	24,718,515	201%	24,786,373	161%
6	5%	14,293,907	-40%	18,237,769	-38%	20,968,324	-29%	24,545,413	-28%
	95%	36,773,020	260%	33,731,224	155%	33,430,416	106%	35,534,017	85%

Tabelle D.4.: Übersicht über die relativen Fehler VaR, Modelltyp LogGam

Modell	Quantil	A		B		C		D	
		Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler
1	5%	433,693	78%	477,589	76%	662,226	67%	869,261	58%
	95%	59,779,494	2916%	50,246,060	2451%	64,746,087	3124%	29,404,272	1323%
2	5%	558,311	76%	1,028,122	58%	1,311,615	48%	1,901,735	29%
	95%	219,458,650	9177%	56,800,194	2229%	50,706,616	1900%	31,566,617	1070%
3	5%	2,360,019	27%	3,506,695	0%	4,511,008	-17%	4,994,347	-18%
	95%	56,088,915	1641%	38,545,133	1000%	31,332,319	709%	27,258,771	546%
4	5%	5,028,757	-16%	5,845,649	-19%	7,266,431	-29%	8,799,522	-39%
	95%	52,372,026	1111%	42,911,875	771%	29,292,505	421%	29,149,257	362%
5	5%	8,867,786	-44%	11,478,338	-54%	13,226,195	-52%	14,304,617	-44%
	95%	48,566,299	688%	37,867,736	409%	34,117,554	293%	33,377,501	235%
6	5%	17,946,842	-65%	22,043,181	-59%	24,547,967	-46%	27,792,283	-40%
	95%	53,474,917	392%	44,793,253	223%	42,467,929	152%	43,553,938	119%

Tabelle D.5.: Übersicht über die relativen Fehler ES, Modelltyp LogGam

Modell	A	B	C	D
Gamma	α 5.70 E-2	1.01 E-1	1.51 E-1	2.07 E-1
	θ 3.51 E+5	2.96 E+5	2.64 E+5	2.41 E+5

Tabelle D.6.: Parameter der Lognormalverteilung, Modelltyp LogGam

Spalte A, E=20.000

$\lambda = 8.33$, $\sigma = 1.78$ Der Erwartungswert eines Verlustes beträgt also 20.000. Das 99.9%-Quantil eines Verlustes beträgt 1.000.000.

Zeile 1, $\lambda=5$




Abbildung D.1.: Modell LogGam, Ergebnis A1, VaR, Wahrer Wert




Abbildung D.2.: Modell LogGam, Ergebnis A1, VaR




Abbildung D.3.: Modell LogGam, Ergebnis A1, ES, Wahrer Wert




Abbildung D.4.: Modell LogGam, Ergebnis A1, ES


Zeile 2, $\lambda=10$ 

Abbildung D.5.: Modell LogGam, Ergebnis A2, VaR, Wahrer Wert




Abbildung D.6.: Modell LogGam, Ergebnis A2, VaR




Abbildung D.7.: Modell LogGam, Ergebnis A2, ES, Wahrer Wert




Abbildung D.8.: Modell LogGam, Ergebnis A2, ES


Zeile 3, $\lambda=25$ 

Abbildung D.9.: Modell LogGam, Ergebnis A3, VaR, Wahrer Wert




Abbildung D.10.: Modell LogGam, Ergebnis A3, VaR




Abbildung D.11.: Modell LogGam, Ergebnis A3, ES, Wahrer Wert




Abbildung D.12.: Modell LogGam, Ergebnis A3, ES

Zeile 4, $\lambda=50$




Abbildung D.13.: Modell LogGam, Ergebnis A4, VaR, Wahrer Wert




Abbildung D.14.: Modell LogGam, Ergebnis A4, VaR




Abbildung D.15.: Modell LogGam, Ergebnis A4, ES, Wahrer Wert




Abbildung D.16.: Modell LogGam, Ergebnis A4, ES


Zeile 5, $\lambda=100$ 

Abbildung D.17.: Modell LogGam, Ergebnis A5, VaR, Wahrer Wert




Abbildung D.18.: Modell LogGam, Ergebnis A5, VaR




Abbildung D.19.: Modell LogGam, Ergebnis A5, ES, Wahrer Wert




Abbildung D.20.: Modell LogGam, Ergebnis A5, ES


Zeile 6, $\lambda=250$ 

Abbildung D.21.: Modell LogGam, Ergebnis A6, VaR, Wahrer Wert




Abbildung D.22.: Modell LogGam, Ergebnis A6, VaR




Abbildung D.23.: Modell LogGam, Ergebnis A6, ES, Wahrer Wert




Abbildung D.24.: Modell LogGam, Ergebnis A6, ES

Spalte B, E=30.000

$\lambda = 9.19$, $\sigma = 1.50$ Der Erwartungswert eines Verlustes beträgt also 30.000. Das 99.9%-Quantil eines Verlustes beträgt 1.000.000.

Zeile 1, $\lambda=5$




Abbildung D.25.: Modell LogGam, Ergebnis B1, VaR, Wahrer Wert




Abbildung D.26.: Modell LogGam, Ergebnis B1, VaR




Abbildung D.27.: Modell LogGam, Ergebnis B1, ES, Wahrer Wert




Abbildung D.28.: Modell LogGam, Ergebnis B1, ES

Zeile 2, $\lambda=10$




Abbildung D.29.: Modell LogGam, Ergebnis B2, VaR, Wahrer Wert




Abbildung D.30.: Modell LogGam, Ergebnis B2, VaR




Abbildung D.31.: Modell LogGam, Ergebnis B2, ES, Wahrer Wert




Abbildung D.32.: Modell LogGam, Ergebnis B2, ES

Zeile 3, $\lambda=25$




Abbildung D.33.: Modell LogGam, Ergebnis B3, VaR, Wahrer Wert




Abbildung D.34.: Modell LogGam, Ergebnis B3, VaR




Abbildung D.35.: Modell LogGam, Ergebnis B3, ES, Wahrer Wert




Abbildung D.36.: Modell LogGam, Ergebnis B3, ES

Zeile 4, $\lambda=50$




Abbildung D.37.: Modell LogGam, Ergebnis B4, VaR, Wahrer Wert




Abbildung D.38.: Modell LogGam, Ergebnis B4, VaR




Abbildung D.39.: Modell LogGam, Ergebnis B4, ES, Wahrer Wert




Abbildung D.40.: Modell LogGam, Ergebnis B4, ES

Zeile 5, $\lambda=100$




Abbildung D.41.: Modell LogGam, Ergebnis B5, VaR, Wahrer Wert




Abbildung D.42.: Modell LogGam, Ergebnis B5, VaR




Abbildung D.43.: Modell LogGam, Ergebnis B5, ES, Wahrer Wert




Abbildung D.44.: Modell LogGam, Ergebnis B5, ES

Zeile 6, $\lambda=250$




Abbildung D.45.: Modell LogGam, Ergebnis B6, VaR, Wahrer Wert




Abbildung D.46.: Modell LogGam, Ergebnis B6, VaR




Abbildung D.47.: Modell LogGam, Ergebnis B6, ES, Wahrer Wert




Abbildung D.48.: Modell LogGam, Ergebnis B6, ES

Spalte C, $E=40.000$

$\lambda = 9.72$, $\sigma = 1.33$ Der Erwartungswert eines Verlustes beträgt also 40.000. Das 99.9%-Quantil eines Verlustes beträgt 1.000.000.


Zeile 1, $\lambda=5$ 

Abbildung D.49.: Modell LogGam, Ergebnis C1, VaR, Wahrer Wert




Abbildung D.50.: Modell LogGam, Ergebnis C1, VaR




Abbildung D.51.: Modell LogGam, Ergebnis C1, ES, Wahrer Wert




Abbildung D.52.: Modell LogGam, Ergebnis C1, ES


Zeile 2, $\lambda=10$ 

Abbildung D.53.: Modell LogGam, Ergebnis C2, VaR, Wahrer Wert




Abbildung D.54.: Modell LogGam, Ergebnis C2, VaR




Abbildung D.55.: Modell LogGam, Ergebnis C2, ES, Wahrer Wert




Abbildung D.56.: Modell LogGam, Ergebnis C2, ES

Zeile 3, $\lambda=25$




Abbildung D.57.: Modell LogGam, Ergebnis C3, VaR, Wahrer Wert




Abbildung D.58.: Modell LogGam, Ergebnis C3, VaR




Abbildung D.59.: Modell LogGam, Ergebnis C3, ES, Wahrer Wert




Abbildung D.60.: Modell LogGam, Ergebnis C3, ES


Zeile 4, $\lambda=50$ 

Abbildung D.61.: Modell LogGam, Ergebnis C4, VaR, Wahrer Wert




Abbildung D.62.: Modell LogGam, Ergebnis C4, VaR




Abbildung D.63.: Modell LogGam, Ergebnis C4, ES, Wahrer Wert




Abbildung D.64.: Modell LogGam, Ergebnis C4, ES


Zeile 5, $\lambda=100$ 

Abbildung D.65.: Modell LogGam, Ergebnis C5, VaR, Wahrer Wert




Abbildung D.66.: Modell LogGam, Ergebnis C5, VaR




Abbildung D.67.: Modell LogGam, Ergebnis C5, ES, Wahrer Wert




Abbildung D.68.: Modell LogGam, Ergebnis C5, ES

Zeile 6, $\lambda=250$




Abbildung D.69.: Modell LogGam, Ergebnis C6, VaR, Wahrer Wert




Abbildung D.70.: Modell LogGam, Ergebnis C6, VaR




Abbildung D.71.: Modell LogGam, Ergebnis C6, ES, Wahrer Wert




Abbildung D.72.: Modell LogGam, Ergebnis C6, ES

Spalte D, E=50.000

$\lambda = 10.10$, $\sigma = 1.20$ Der Erwartungswert eines Verlustes beträgt also 50.000. Das 99.9%-Quantil eines Verlustes beträgt 1.000.000.

Zeile 1, $\lambda=5$




Abbildung D.73.: Modell LogGam, Ergebnis D1, VaR, Wahrer Wert




Abbildung D.74.: Modell LogGam, Ergebnis D1, VaR




Abbildung D.75.: Modell LogGam, Ergebnis D1, ES, Wahrer Wert




Abbildung D.76.: Modell LogGam, Ergebnis D1, ES

Zeile 2, $\lambda=10$




Abbildung D.77.: Modell LogGam, Ergebnis D2, VaR, Wahrer Wert




Abbildung D.78.: Modell LogGam, Ergebnis D2, VaR




Abbildung D.79.: Modell LogGam, Ergebnis D2, ES, Wahrer Wert




Abbildung D.80.: Modell LogGam, Ergebnis D2, ES

Zeile 3, $\lambda=25$




Abbildung D.81.: Modell LogGam, Ergebnis D3, VaR, Wahrer Wert




Abbildung D.82.: Modell LogGam, Ergebnis D3, VaR




Abbildung D.83.: Modell LogGam, Ergebnis D3, ES, Wahrer Wert




Abbildung D.84.: Modell LogGam, Ergebnis D3, ES

Zeile 4, $\lambda=50$




Abbildung D.85.: Modell LogGam, Ergebnis D4, VaR, Wahrer Wert




Abbildung D.86.: Modell LogGam, Ergebnis D4, VaR




Abbildung D.87.: Modell LogGam, Ergebnis D4, ES, Wahrer Wert




Abbildung D.88.: Modell LogGam, Ergebnis D4, ES

Zeile 5, $\lambda=100$




Abbildung D.89.: Modell LogGam, Ergebnis D5, VaR, Wahrer Wert




Abbildung D.90.: Modell LogGam, Ergebnis D5, VaR




Abbildung D.91.: Modell LogGam, Ergebnis D5, ES, Wahrer Wert




Abbildung D.92.: Modell LogGam, Ergebnis D5, ES

Zeile 6, $\lambda=250$




Abbildung D.93.: Modell LogGam, Ergebnis D6, VaR, Wahrer Wert




Abbildung D.94.: Modell LogGam, Ergebnis D6, VaR




Abbildung D.95.: Modell LogGam, Ergebnis D6, ES, Wahrer Wert




Abbildung D.96.: Modell LogGam, Ergebnis D6, ES

E. Modell Lognormal-Mischung

In diesem Abschnitt werden die Ergebnisse des Modells Lognormal-Mischung detailliert aufgelistet. Zunächst werden die Tabellen aus Kapitel 6 wiederholt. Im Anschluss werden alle Grafiken zur Ermittlung der wahren 99.9%-Quantile und die Histogramme der MCS zu allen verschiedenen Parametern dargestellt.

Modell			A	B	C	D
	lambda	Erwartungswert	20,000	30,000	40,000	50,000
		99.9%-Quantil	1,000,000	1,000,000	1,000,000	1,000,000
		Anteil Datenverlust durch Threshold	73%	58%	46%	37%
1	5		1.3	2.1	2.7	3.2
2	10		2.7	4.2	5.4	6.3
3	25		6.7	10.5	13.4	15.8
4	50		13.4	20.9	26.9	31.5
5	100		26.7	41.9	53.7	63.1
6	250		66.9	104.7	134.3	157.6

Tabelle E.1.: Modellspezifikation Modelltyp LogMis

Modell	A	B	C	D
1	2.2	2.0	1.9	1.9
2	2.9	2.7	2.6	2.6
3	5.0	4.2	4.0	4.2
4	7.5	6.3	6.1	6.3
5	12.0	9.4	9.3	9.9
6	22.3	17.8	17.8	19.5

Tabelle E.2.: tatsächliche Werte VaR Modelltyp LogMis

Modell	A	B	C	D
1	4.4	3.3	2.9	2.6
2	13.6	4.7	3.7	3.4
3	11.0	7.0	5.7	5.3
4	16.9	10.4	8.3	7.8
5	28.6	15.2	12.5	11.7
6	53.0	29.4	22.9	21.7

Tabelle E.3.: tatsächliche Werte ES Modelltyp LogMis

Modell	Quantil	A		B		C		D	
		Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler
1	5%	193,770	91%	250,598	87%	471,724	76%	547,035	71%
	95%	24,328,018	1027%	19,560,944	896%	17,497,452	798%	11,906,121	522%
2	5%	367,310	87%	734,116	73%	949,203	64%	1,278,858	51%
	95%	32,630,091	1012%	22,005,936	710%	11,609,867	342%	10,347,666	293%
3	5%	1,175,156	77%	1,878,306	56%	2,420,704	40%	2,794,741	33%
	95%	62,302,067	1146%	22,968,057	443%	15,091,132	273%	11,166,051	167%
4	5%	2,643,979	65%	3,656,595	42%	4,259,195	30%	5,262,031	16%
	95%	49,918,441	563%	21,041,429	233%	14,315,838	136%	13,559,889	116%
5	5%	5,440,127	55%	6,657,087	29%	7,455,664	20%	8,951,098	10%
	95%	56,089,803	366%	21,873,697	134%	18,776,920	102%	16,015,253	61%
6	5%	12,580,769	44%	13,933,567	22%	16,282,518	8%	18,835,694	3%
	95%	51,562,604	131%	29,750,172	67%	24,949,717	41%	26,208,736	34%

Tabelle E.4.: Übersicht über die relativen Fehler VaR, Modelltyp LogMis

Modell	Quantil	A		B		C		D	
		Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler
1	5%	226,383	95%	279,310	92%	558,252	81%	626,717	76%
	95%	81,083,640	1749%	47,563,094	1344%	39,101,424	1264%	21,304,432	725%
2	5%	426,294	97%	882,539	81%	1,118,860	70%	1,530,151	55%
	95%	107,886,620	696%	57,113,828	1113%	20,644,396	451%	15,785,263	362%
3	5%	1,449,178	87%	2,288,654	67%	2,852,102	50%	3,299,739	38%
	95%	175,496,228	1502%	41,852,815	496%	24,878,558	335%	16,263,581	205%
4	5%	3,335,078	80%	4,311,584	58%	5,087,107	39%	6,096,556	22%
	95%	124,289,137	636%	33,707,715	225%	20,563,649	148%	18,201,232	134%
5	5%	7,064,234	75%	8,094,624	47%	8,570,545	31%	9,999,995	15%
	95%	111,998,180	292%	33,004,521	117%	25,329,840	103%	20,029,484	71%
6	5%	16,343,424	69%	16,459,015	44%	18,222,908	20%	20,436,373	6%
	95%	88,616,580	67%	41,434,135	41%	30,579,671	34%	29,842,128	38%

Tabelle E.5.: Übersicht über die relativen Fehler ES, Modelltyp LogMis

Modell		A	B	C	D
Lognormal	μ	8.33 E+0	8.19 E+0	9.71 E+0	1.01 E+1
	σ	1.78 E+0	1.50 E+0	1.33 E+0	1.20 E+0
Pareto	α	1.49 E+0	1.90 E+0	2.29 E+0	2.73 E+0
	θ	9.82 E+3	2.69 E+4	5.17 E+4	8.64 E+4
Weibull	τ	3.49 E-1	4.25 E-1	4.89 E-1	5.46 E-1
	θ	3.94 E+3	1.06 E+4	1.91 E+4	2.91 E+4
Gamma	α	5.70 E-2	1.01 E-1	1.51 E-1	2.07 E-1
	θ	3.51 E+5	2.96 E+5	2.64 E+5	2.41 E+5

Tabelle E.6.: Parameter der Lognormalverteilung, Modelltyp LogMis

Spalte A, E=20.000

$\lambda = 8.33$, $\sigma = 1.78$ Der Erwartungswert eines Verlustes beträgt also 20.000. Das 99.9%-Quantil eines Verlustes beträgt 1.000.000.

Zeile 1, $\lambda=5$




Abbildung E.1.: Modell LogMis, Ergebnis A1, VaR, Wahrer Wert




Abbildung E.2.: Modell LogMis, Ergebnis A1, VaR




Abbildung E.3.: Modell LogMis, Ergebnis A1, ES, Wahrer Wert




Abbildung E.4.: Modell LogMis, Ergebnis A1, ES


Zeile 2, $\lambda=10$ 

Abbildung E.5.: Modell LogMis, Ergebnis A2, VaR, Wahrer Wert




Abbildung E.6.: Modell LogMis, Ergebnis A2, VaR




Abbildung E.7.: Modell LogMis, Ergebnis A2, ES, Wahrer Wert




Abbildung E.8.: Modell LogMis, Ergebnis A2, ES


Zeile 3, $\lambda=25$ 

Abbildung E.9.: Modell LogMis, Ergebnis A3, VaR, Wahrer Wert




Abbildung E.10.: Modell LogMis, Ergebnis A3, VaR




Abbildung E.11.: Modell LogMis, Ergebnis A3, ES, Wahrer Wert




Abbildung E.12.: Modell LogMis, Ergebnis A3, ES

Zeile 4, $\lambda=50$




Abbildung E.13.: Modell LogMis, Ergebnis A4, VaR, Wahrer Wert




Abbildung E.14.: Modell LogMis, Ergebnis A4, VaR




Abbildung E.15.: Modell LogMis, Ergebnis A4, ES, Wahrer Wert




Abbildung E.16.: Modell LogMis, Ergebnis A4, ES


Zeile 5, $\lambda=100$ 

Abbildung E.17.: Modell LogMis, Ergebnis A5, VaR, Wahrer Wert




Abbildung E.18.: Modell LogMis, Ergebnis A5, VaR




Abbildung E.19.: Modell LogMis, Ergebnis A5, ES, Wahrer Wert




Abbildung E.20.: Modell LogMis, Ergebnis A5, ES


Zeile 6, $\lambda=250$ 

Abbildung E.21.: Modell LogMis, Ergebnis A6, VaR, Wahrer Wert




Abbildung E.22.: Modell LogMis, Ergebnis A6, VaR




Abbildung E.23.: Modell LogMis, Ergebnis A6, ES, Wahrer Wert




Abbildung E.24.: Modell LogMis, Ergebnis A6, ES

Spalte B, E=30.000

$\lambda = 9.19$, $\sigma = 1.50$ Der Erwartungswert eines Verlustes beträgt also 30.000. Das 99.9%-Quantil eines Verlustes beträgt 1.000.000.

Zeile 1, $\lambda=5$




Abbildung E.25.: Modell LogMis, Ergebnis B1, VaR, Wahrer Wert




Abbildung E.26.: Modell LogMis, Ergebnis B1, VaR




Abbildung E.27.: Modell LogMis, Ergebnis B1, ES, Wahrer Wert




Abbildung E.28.: Modell LogMis, Ergebnis B1, ES

Zeile 2, $\lambda=10$




Abbildung E.29.: Modell LogMis, Ergebnis B2, VaR, Wahrer Wert




Abbildung E.30.: Modell LogMis, Ergebnis B2, VaR




Abbildung E.31.: Modell LogMis, Ergebnis B2, ES, Wahrer Wert




Abbildung E.32.: Modell LogMis, Ergebnis B2, ES

Zeile 3, $\lambda=25$




Abbildung E.33.: Modell LogMis, Ergebnis B3, VaR, Wahrer Wert




Abbildung E.34.: Modell LogMis, Ergebnis B3, VaR




Abbildung E.35.: Modell LogMis, Ergebnis B3, ES, Wahrer Wert




Abbildung E.36.: Modell LogMis, Ergebnis B3, ES

Zeile 4, $\lambda=50$




Abbildung E.37.: Modell LogMis, Ergebnis B4, VaR, Wahrer Wert




Abbildung E.38.: Modell LogMis, Ergebnis B4, VaR




Abbildung E.39.: Modell LogMis, Ergebnis B4, ES, Wahrer Wert




Abbildung E.40.: Modell LogMis, Ergebnis B4, ES

Zeile 5, $\lambda=100$




Abbildung E.41.: Modell LogMis, Ergebnis B5, VaR, Wahrer Wert




Abbildung E.42.: Modell LogMis, Ergebnis B5, VaR




Abbildung E.43.: Modell LogMis, Ergebnis B5, ES, Wahrer Wert




Abbildung E.44.: Modell LogMis, Ergebnis B5, ES

Zeile 6, $\lambda=250$




Abbildung E.45.: Modell LogMis, Ergebnis B6, VaR, Wahrer Wert




Abbildung E.46.: Modell LogMis, Ergebnis B6, VaR




Abbildung E.47.: Modell LogMis, Ergebnis B6, ES, Wahrer Wert




Abbildung E.48.: Modell LogMis, Ergebnis B6, ES

Spalte C, $E=40.000$

$\lambda = 9.72$, $\sigma = 1.33$ Der Erwartungswert eines Verlustes beträgt also 40.000. Das 99.9%-Quantil eines Verlustes beträgt 1.000.000.


Zeile 1, $\lambda=5$ 

Abbildung E.49.: Modell LogMis, Ergebnis C1, VaR, Wahrer Wert




Abbildung E.50.: Modell LogMis, Ergebnis C1, VaR




Abbildung E.51.: Modell LogMis, Ergebnis C1, ES, Wahrer Wert




Abbildung E.52.: Modell LogMis, Ergebnis C1, ES


Zeile 2, $\lambda=10$ 

Abbildung E.53.: Modell LogMis, Ergebnis C2, VaR, Wahrer Wert




Abbildung E.54.: Modell LogMis, Ergebnis C2, VaR




Abbildung E.55.: Modell LogMis, Ergebnis C2, ES, Wahrer Wert




Abbildung E.56.: Modell LogMis, Ergebnis C2, ES

Zeile 3, $\lambda=25$




Abbildung E.57.: Modell LogMis, Ergebnis C3, VaR, Wahrer Wert




Abbildung E.58.: Modell LogMis, Ergebnis C3, VaR




Abbildung E.59.: Modell LogMis, Ergebnis C3, ES, Wahrer Wert




Abbildung E.60.: Modell LogMis, Ergebnis C3, ES


Zeile 4, $\lambda=50$ 

Abbildung E.61.: Modell LogMis, Ergebnis C4, VaR, Wahrer Wert




Abbildung E.62.: Modell LogMis, Ergebnis C4, VaR




Abbildung E.63.: Modell LogMis, Ergebnis C4, ES, Wahrer Wert




Abbildung E.64.: Modell LogMis, Ergebnis C4, ES


Zeile 5, $\lambda=100$ 

Abbildung E.65.: Modell LogMis, Ergebnis C5, VaR, Wahrer Wert




Abbildung E.66.: Modell LogMis, Ergebnis C5, VaR




Abbildung E.67.: Modell LogMis, Ergebnis C5, ES, Wahrer Wert




Abbildung E.68.: Modell LogMis, Ergebnis C5, ES

Zeile 6, $\lambda=250$




Abbildung E.69.: Modell LogMis, Ergebnis C6, VaR, Wahrer Wert




Abbildung E.70.: Modell LogMis, Ergebnis C6, VaR




Abbildung E.71.: Modell LogMis, Ergebnis C6, ES, Wahrer Wert




Abbildung E.72.: Modell LogMis, Ergebnis C6, ES

Spalte D, E=50.000

$\lambda = 10.10$, $\sigma = 1.20$ Der Erwartungswert eines Verlustes beträgt also 50.000. Das 99.9%-Quantil eines Verlustes beträgt 1.000.000.

Zeile 1, $\lambda=5$




Abbildung E.73.: Modell LogMis, Ergebnis D1, VaR, Wahrer Wert




Abbildung E.74.: Modell LogMis, Ergebnis D1, VaR




Abbildung E.75.: Modell LogMis, Ergebnis D1, ES, Wahrer Wert




Abbildung E.76.: Modell LogMis, Ergebnis D1, ES

Zeile 2, $\lambda=10$




Abbildung E.77.: Modell LogMis, Ergebnis D2, VaR, Wahrer Wert




Abbildung E.78.: Modell LogMis, Ergebnis D2, VaR




Abbildung E.79.: Modell LogMis, Ergebnis D2, ES, Wahrer Wert




Abbildung E.80.: Modell LogMis, Ergebnis D2, ES

Zeile 3, $\lambda=25$




Abbildung E.81.: Modell LogMis, Ergebnis D3, VaR, Wahrer Wert




Abbildung E.82.: Modell LogMis, Ergebnis D3, VaR




Abbildung E.83.: Modell LogMis, Ergebnis D3, ES, Wahrer Wert




Abbildung E.84.: Modell LogMis, Ergebnis D3, ES

Zeile 4, $\lambda=50$




Abbildung E.85.: Modell LogMis, Ergebnis D4, VaR, Wahrer Wert




Abbildung E.86.: Modell LogMis, Ergebnis D4, VaR




Abbildung E.87.: Modell LogMis, Ergebnis D4, ES, Wahrer Wert




Abbildung E.88.: Modell LogMis, Ergebnis D4, ES

Zeile 5, $\lambda=100$




Abbildung E.89.: Modell LogMis, Ergebnis D5, VaR, Wahrer Wert




Abbildung E.90.: Modell LogMis, Ergebnis D5, VaR




Abbildung E.91.: Modell LogMis, Ergebnis D5, ES, Wahrer Wert




Abbildung E.92.: Modell LogMis, Ergebnis D5, ES

Zeile 6, $\lambda=250$




Abbildung E.93.: Modell LogMis, Ergebnis D6, VaR, Wahrer Wert




Abbildung E.94.: Modell LogMis, Ergebnis D6, VaR




Abbildung E.95.: Modell LogMis, Ergebnis D6, ES, Wahrer Wert




Abbildung E.96.: Modell LogMis, Ergebnis D6, ES

F. Modell Bayes–hochgewichtet

In diesem Abschnitt werden die Ergebnisse des Modells BayHoch detailliert aufgelistet. Zunächst werden die Tabellen aus Kapitel 6 wiederholt. Im Anschluss werden alle Grafiken zur Ermittlung der wahren 99.9%-Quantile und die Histogramme der MCS zu allen verschiedenen Parametern dargestellt.

Modell	1	A	B	D
	2			
A		$\mu_0=0.5 \mu_{\text{real}}$ $\kappa_0=100$ $\sigma_0^2=0.5 \sigma_{\text{real}}$ $\nu_0=100$	$\mu_0=1.0 \mu_{\text{real}}$ $\kappa_0=100$ $\sigma_0^2=0.5 \sigma_{\text{real}}$ $\nu_0=100$	$\mu_0=1.5 \mu_{\text{real}}$ $\kappa_0=100$ $\sigma_0^2=0.5 \sigma_{\text{real}}$ $\nu_0=100$
B		$\mu_0=0.5 \mu_{\text{real}}$ $\kappa_0=100$ $\sigma_0^2=1.0 \sigma_{\text{real}}$ $\nu_0=100$	$\mu_0=1.0 \mu_{\text{real}}$ $\kappa_0=100$ $\sigma_0^2=1.0 \sigma_{\text{real}}$ $\nu_0=100$	$\mu_0=1.5 \mu_{\text{real}}$ $\kappa_0=100$ $\sigma_0^2=1.0 \sigma_{\text{real}}$ $\nu_0=100$
C		$\mu_0=0.5 \mu_{\text{real}}$ $\kappa_0=100$ $\sigma_0^2=1.5 \sigma_{\text{real}}$ $\nu_0=100$	$\mu_0=1.0 \mu_{\text{real}}$ $\kappa_0=100$ $\sigma_0^2=1.5 \sigma_{\text{real}}$ $\nu_0=100$	$\mu_0=1.5 \mu_{\text{real}}$ $\kappa_0=100$ $\sigma_0^2=1.5 \sigma_{\text{real}}$ $\nu_0=100$

Tabelle F.1.: Modellspezifikation Modelltyp BayHoch

Modell	1	A		B		C	
	2	Quantil		Wert	Rel. Fehler	Wert	Rel. Fehler
A	5%	92,006	96%	414,074	82%	126,302,378	-5258%
	95%	1,218,882	-48%	1,057,770	-55%	647,485,234	27367%
B	5%	323,441	86%	1,944,238	18%	387,406,763	-16334%
	95%	3,023,375	28%	3,969,673	68%	1,568,145,845	66422%
C	5%	854,150	64%	6,439,216	-173%	1,094,419,101	-46326%
	95%	6,440,760	173%	12,043,091	411%	3,329,368,307	141134%

Tabelle F.2.: Übersicht über die relativen Fehler VaR, Modelltyp BayHoch

Spalte A, $\mu_0 = 0.5\mu_{real}$

Zeile A $\sigma_0^2 = 0.5\sigma_{real}^2$




Abbildung F.1.: Modell BayHoch, Ergebnis A1AA, VaR

Zeile B, $\sigma_0^2 = 1.0\sigma_{real}^2$




Abbildung F.2.: Modell BayHoch, Ergebnis A1AB, VaR

Zeile C, $\sigma_0^2 = 1.5\sigma_{real}^2$




Abbildung F.3.: Modell BayHoch, Ergebnis A1AC, VaR

Spalte B, $\mu_0 = 1.0\mu_{real}$

Zeile A, $\sigma_0^2 = 0.5\sigma_{real}^2$




Abbildung F.4.: Modell BayHoch, Ergebnis A1BA, VaR

Zeile B, $\sigma_0^2 = 1.0\sigma_{real}^2$




Abbildung F.5.: Modell BayHoch, Ergebnis A1BB, VaR

Zeile C, $\sigma_0^2 = 1.5\sigma_{real}^2$




Abbildung F.6.: Modell BayHoch, Ergebnis A1BC, VaR

Spalte C, $\mu_0 = 1.5\mu_{real}$

Zeile A, $\sigma_0^2 = 0.5\sigma_{real}^2$




Abbildung F.7.: Modell BayHoch, Ergebnis A1CA, VaR

Zeile B, $\sigma_0^2 = 1.0\sigma_{real}^2$




Abbildung F.8.: Modell BayHoch, Ergebnis A1CB, VaR

Zeile C, $\sigma_0^2 = 1.5\sigma_{real}^2$




Abbildung F.9.: Modell BayHoch, Ergebnis A1CC, VaR

G. Modell Bayes–niedriggewichtet

In diesem Abschnitt werden die Ergebnisse des Modells BayNiedrig detailliert aufgelistet. Zunächst werden die Tabellen aus Kapitel 6 wiederholt. Im Anschluss werden alle Grafiken zur Ermittlung der wahren 99.9%-Quantile und die Histogramme der MCS zu allen verschiedenen Parametern dargestellt.

Modell	1	A	B	D
	2			
A		$\mu_0=0.5 \mu_{\text{real}}$	$\mu_0=1.0 \mu_{\text{real}}$	$\mu_0=1.5 \mu_{\text{real}}$
		$\kappa_0=0.01$	$\kappa_0=0.01$	$\kappa_0=0.01$
		$\sigma_0^2=0.5 \sigma_{\text{real}}$	$\sigma_0^2=0.5 \sigma_{\text{real}}$	$\sigma_0^2=0.5 \sigma_{\text{real}}$
		$\nu_0=0.01$	$\nu_0=0.01$	$\nu_0=0.01$
B		$\mu_0=0.5 \mu_{\text{real}}$	$\mu_0=1.0 \mu_{\text{real}}$	$\mu_0=1.5 \mu_{\text{real}}$
		$\kappa_0=0.01$	$\kappa_0=0.01$	$\kappa_0=0.01$
		$\sigma_0^2=1.0 \sigma_{\text{real}}$	$\sigma_0^2=1.0 \sigma_{\text{real}}$	$\sigma_0^2=1.0 \sigma_{\text{real}}$
		$\nu_0=0.01$	$\nu_0=0.01$	$\nu_0=0.01$
C		$\mu_0=0.5 \mu_{\text{real}}$	$\mu_0=1.0 \mu_{\text{real}}$	$\mu_0=1.5 \mu_{\text{real}}$
		$\kappa_0=0.01$	$\kappa_0=0.01$	$\kappa_0=0.01$
		$\sigma_0^2=1.5 \sigma_{\text{real}}$	$\sigma_0^2=1.5 \sigma_{\text{real}}$	$\sigma_0^2=1.5 \sigma_{\text{real}}$
		$\nu_0=0.01$	$\nu_0=0.01$	$\nu_0=0.01$

Tabelle G.1.: Modellspezifikation Modelltyp BayNiedrig

Modell	1	A		B		C	
	2 Quantil	Wert	Rel. Fehler	Wert	Rel. Fehler	Wert	Rel. Fehler
A	5%	702,576	70%	381,071	84%	1,145,066	51%
	95%	10,665,363	352%	8,271,631	251%	14,581,916	519%
B	5%	623,876	74%	354,855	85%	1,046,673	56%
	95%	11,267,449	378%	7,762,111	229%	14,916,689	533%
C	5%	628,895	73%	369,762	84%	942,341	60%
	95%	15,716,058	567%	9,784,655	315%	17,073,246	624%

Tabelle G.2.: Übersicht über die relativen Fehler VaR, Modelltyp BayNiedrig

Spalte A, $\mu_0 = 0.5\mu_{real}$

Zeile A $\sigma_0^2 = 0.5\sigma_{real}^2$




Abbildung G.1.: Modell BayNiedrig, Ergebnis A1AA, VaR

Zeile B, $\sigma_0^2 = 1.0\sigma_{real}^2$




Abbildung G.2.: Modell BayNiedrig, Ergebnis A1AB, VaR

Zeile C, $\sigma_0^2 = 1.5\sigma_{real}^2$




Abbildung G.3.: Modell BayNiedrig, Ergebnis A1AC, VaR

Spalte B, $\mu_0 = 1.0\mu_{real}$

Zeile A, $\sigma_0^2 = 0.5\sigma_{real}^2$




Abbildung G.4.: Modell BayNiedrig, Ergebnis A1BA, VaR

Zeile B, $\sigma_0^2 = 1.0\sigma_{real}^2$




Abbildung G.5.: Modell BayNiedrig, Ergebnis A1BB, VaR

Zeile C, $\sigma_0^2 = 1.5\sigma_{real}^2$




Abbildung G.6.: Modell BayNiedrig, Ergebnis A1BC, VaR

Spalte C, $\mu_0 = 1.5\mu_{real}$

Zeile A, $\sigma_0^2 = 0.5\sigma_{real}^2$




Abbildung G.7.: Modell BayNiedrig, Ergebnis A1CA, VaR

Zeile B, $\sigma_0^2 = 1.0\sigma_{real}^2$




Abbildung G.8.: Modell BayNiedrig, Ergebnis A1CB, VaR

Zeile C, $\sigma_0^2 = 1.5\sigma_{real}^2$




Abbildung G.9.: Modell BayNiedrig, Ergebnis A1CC, VaR

Literaturverzeichnis

ABN AMRO u. a. 2003 ABN AMRO ; BANCA INTESA ; BNP PARIBAS ; BMO FINANCIAL GROUP ; CREDIT LYONNAIS ; CITIGROUP ; DEUTSCHE BANK ; ING ; JP MORGAN CHASE ; RBC FINANCIAL GROUP ; ROYAL BANK OF SCOTLAND ; SAN PAOLO IMI ; SUMITOMO MITSUI BC: An LDA-Based Advanced Measurement Approach for the Measurement of Operational Risk – Ideas, Issues and Emerging Practices / Industry Technical Working Group on Operational Risk. Mai 2003. – Working Paper

Alexander 1996 ALEXANDER, Carol (Hrsg.): *The Handbook of Risk Management and Analysis*. John Wiley & Sons, Inc, 1996

Alexander 1998a ALEXANDER, Carol (Hrsg.): *Risk Management and Analysis*. Bd. 1: Measuring and modelling financial risk. John Wiley & Sons, Inc, 1998

Alexander 1998b ALEXANDER, Carol (Hrsg.): *Risk Management and Analysis*. Bd. 2: New markets and products. John Wiley & Sons, Inc, 1998

Alexander 2003a ALEXANDER, Carol (Hrsg.): *Operational Risk – Regulation, Analysis and Management*. Prentice Hall, 2003

Alexander 2003b ALEXANDER, Carol: *Statistical models of operational loss*. Siehe (Alexander 2003a)

Anders 2001 ANDERS, Ulrich: Qualitative Anforderungen an das Management operationeller Risiken. In: *Die Bank* 6 (2001), S. 442–446

Artzner u. a. 1999 ARTZNER, Philippe ; DELABAEN, Freddy ; EBER, Jaen-Marc ; HEATH, David: Coherent Measures of Risk. In: *Mathematical Finance* 9 (1999), Juli, Nr. 3, S. 203–228

Basel Committee on Banking Supervision 2003a BASEL COMMITTEE ON BANKING SUPERVISION: *Consultative Document – Overview of The New Basel Capital Accord*. Bank for International Settlements, Juni 2003. – Issued for comment by 31 July 2003

- Basel Committee on Banking Supervision 2003b** BASEL COMMITTEE ON BANKING SUPERVISION: *Consultative Document – The New Basel Capital Accord*. Bank for International Settlements, April 2003. – Issued for comment by 31 July 2003
- Basel Committee on Banking Supervision 2003c** BASEL COMMITTEE ON BANKING SUPERVISION: *Sound Practices for the Management and Supervision of Operational Risk*. Bank for International Settlements, Februar 2003
- Basel Committee on Banking Supervision 2004** BASEL COMMITTEE ON BANKING SUPERVISION: *International Convergence of Capital Measurement and Capital Standards – A Revised Framework*. Bank for International Settlements, Juni 2004
- Baud u. a. 2002** BAUD, Nicolas ; FRACHOT, Antoine ; RONCALLI, Thierry: Internal data, external data and consortium data for operational risk measurement: How to pool data properly? / Groupe der Recherche Opérationelle, Crédit Lyonnais, France. Juni 2002. – Working Paper
- Bayarri und Berger 2004** BAYARRI, M. J. ; BERGER, J. O.: The Interplay of Bayesian and Frequentist Analysis. In: *Statistical Science* 19 (2004), Februar, Nr. 1, S. 58–80
- Bernardo und Smith 2000** BERNARDO, Joseph M. ; SMITH, Adrian F. M.: *Bayesian Theory*. John Wiley & Sons, Inc, 2000
- Bühlmann und Straub 1970** BÜHLMANN, H. ; STRAUB, E.: Glaubwürdigkeit für Schadensätze. In: *Mitteilungen der Vereinigung Schweizerischer Versicherungsmathematiker* 70 (1970), S. 111–133
- Boos und Schulte-Mattler 2001** BOOS, Karl-Heinz ; SCHULTE-MATTTLER, Hermann: Basel II: Methoden zur Quantifizierung operationeller Risiken. In: *Die Bank* 8 (2001), S. 549–553
- Buchmüller 2001** BUCHMÜLLER, Patrik: Die Berücksichtigung des operationellen Risikos in der neuen Basler Eigenkapitalvereinbarung / Eberhard-Karls-Universität Tübingen. Dezember 2001. – Working Paper
- Buchmüller 2002** BUCHMÜLLER, Patrik: Die Berücksichtigung des operationellen Risikos in der neuen Basler Eigenkapitalvereinbarung: Stand und Beurteilung. In: *Zeitschrift für Bankrecht und Bankwirtschaft* 14 (2002), Nr. 5, S. 385–394
- Chappell und Dowd 1999** CHAPPELL, David ; DOWD, Kevin: In: *Financial Engineering News* 9 (1999)
- Cruz 2004** CRUZ, Marcelo (Hrsg.): *Operational Risk Modelling and Analysis*. Risk Books, 2004

- Cruz 2002** CRUZ, Marcelo G.: *Modeling, measuring and hedging operational risk*. John Wiley & Sons, Inc, 2002
- Danielsson 2002** DANIELSSON, Jon: The emperor has no clothes: Limits to risk modelling. In: *Journal of Banking & Finance* 26 (2002), Nr. 7, S. 1273–1296
- David 1981** DAVID, Herbert: *Order Statistics*. John Wiley & Sons, Inc, 1981
- Davis 2005** DAVIS, Ellen L. (Hrsg.): *Operational Risk: Practical Approaches to Implementation*. Risk Books, 2005
- Doerig 2000** DOERIG, Hans-Ulrich: Operational Risks in Financial Services – An old Challenge in a new Environment / Institut International D’Etudes Bancaires. 2000. – Working Paper
- Dowd 1998** DOWD, Kevin: *Beyond Value at Risk*. John Wiley & Sons, Inc, 1998
- Draper 2005** DRAPER, David: Bayesian Modeling, Inference and Prediction / Department of Applied Mathematics and Statistics, University of California, Santa Cruz. 2005. – Working Paper
- Dupire 1998** DUPIRE, Bruno (Hrsg.): *Monte Carlo – Methodologies and Applications for Pricing and Risk Management*. Risk Books, 1998
- Efron 1986** EFRON, B.: Why Isn’t Everyone a Bayesian? In: *The American Statistician* 40 (1986), Februar, Nr. 1, S. 1–5
- Embrechts u. a. 2002** EMBRECHTS, Paul ; KAUFMANN, Roger ; SAMORODNITSKY, Gennady: Ruin theory revisited: stochastic models for operational risk / Department of Mathematics ETH Zürich and School of ORIE Cornell University. Dezember 2002. – Working Paper
- ETH-UNS Fallstudienbüro 2001** ETH-UNS FALLSTUDIENBÜRO: *Szenarioanalyse – eine kurze Einführung*. 2001
- Europäisches Parlament und Rat 2006a** EUROPÄISCHES PARLAMENT UND RAT: *Richtlinie 2006/48/EG des Europäischen Parlaments und des Rates vom 14. Juni 2006 über die angemessene Eigenkapitalausstattung von Wertpapierfirmen und Kreditinstituten*. Juni 2006
- Europäisches Parlament und Rat 2006b** EUROPÄISCHES PARLAMENT UND RAT: *Richtlinie 2006/48/EG des Europäischen Parlaments und des Rates vom 14. Juni 2006 über die Aufnahme und Ausübung der Tätigkeit der Kreditinstitute*. Juni 2006
- Fahey und Randall 1998** FAHEY, Liam (Hrsg.) ; RANDALL, Robert M. (Hrsg.): *Learning from the Future – competitive foresight scenarios*. John Wiley & Sons, Inc, 1998

- Fischer 2001** FISCHER, Thomas R.: Operationale Risiken im neuen Basler Kapitalakkord. In: *Zeitschrift für das gesamte Kreditwesen* 12 (2001), S. 662–687
- de Fontnouvelle u. a. 2003a** FONTNOUVELLE, Patrick de ; DEJESUS-RUEFF, Virginia ; JORDAN, John ; ROSENGREN, Eric: Capital and Risk: New Evidence on Implications of Large Operational Losses / Federal Reserve Bank of Boston. September 2003. – Working Paper
- de Fontnouvelle u. a. 2003b** FONTNOUVELLE, Patrick de ; DEJESUS-RUEFF, Virginia ; JORDAN, John ; ROSENGREN, Eric: Using Loss Data to Quantify Operational Risk / Federal Reserve Bank of Boston. April 2003. – Working Paper
- de Fontnouvelle u. a. 2004** FONTNOUVELLE, Patrick de ; ROSENGREN, Eric ; JORDAN, John: Capital and Risk: New Evidence on Implications of Large Operational Losses / Federal Reserve Bank of Boston and FitchRisk. Juni 2004. – Working Paper
- Frachot und Roncalli 2002** FRACHOT, Antoine ; RONCALLI, Thierry: Mixing internal and external data for managing operational risk / Groupe der Recherche Opérationnelle, Crédit Lyonnais, France. Januar 2002. – Working Paper
- Giudici und Bilotta 2004** GIUDICI, Paolo ; BILOTTA, Annalisa: Modelling Operational Losses: A Bayesian Approach. In: *Quality And Reliability Engineering International* 20 (2004), S. 407–417
- Godet 1987** GODET, M.: *Scenarios and Strategic Management*. Butterworths, 1987
- Goodbody 2003** GOODBODY, Michael: FSA to offer guidance not rules on operational risk. In: *Banking Technology* 20 (2003), April, Nr. 3, S. 5
- Götze 1993** GÖTZE, Ulrich: *Szenario-Technik in der strategischen Unternehmensplanung*. Deutscher Universitätsverlag, 1993
- Höfer und Schrott 2003** HÖFER, Susanne ; SCHROTT, Alexander: Mit Basel II rücken operationelle Risiken stärker in den Blick. In: *Betriebswirtschaftliche Blätter* 52 (2003), Nr. 3, S. 158–160
- Hoffman 2000/2001** HOFFMAN, Douglas G.: Into the valley. In: *RiskProfessional* 2/10 (2000/2001)
- Hoffman 2002** HOFFMAN, Douglas G.: *Managing Operational Risk - 20 Firmwide Best Practice Strategies*. John Wiley & Sons, Inc, 2002
- Iversen 2000** IVERSEN, Gudmund: Why Should We Even Teach Statistics? – A Bayesian Perspective / Department of Mathematics and Statistics, Swarthmore College. 2000. – Working Paper

- Jaynes 1984** JAYNES, Ed T.: Bayesian Methods: General Background. In: JUSTICE, J. H. (Hrsg.): *Maximum Entropy and Bayesian Methods in Applied Statistics*, Cambridge University Press, 1984, S. 1–25
- Jorion 1997** JORION, Philippe: *Value at Risk – The New Benchmark for Controlling Derivatives Risk*. McGraw-Hill, 1997
- Kahn und Wiener 1967** KAHN, Herman ; WIENER, Anthony J.: *The year 2000*. Macmillan, 1967
- Kaiser und Köhne 2004** KAISER, Thomas ; KÖHNE, Marc: *Operationelle Risiken in Finanzinstituten – Wege zur Umsetzung von Basel II und CAD 3*. Gabler, 2004
- Kaufmann und Dröse 2000** KAUFMANN, Marcel ; DRÖSE, Günter: Operational Risk Management: Risikotransfer durch Versicherung. In: *Die Bank* 11 (2000), November. – Sonderdruck
- King 2001** KING, Jack: *Operational Risk*. John Wiley & Sons, Inc, 2001
- Klomfass und Quandt 2001** KLOMFASS, Markus ; QUANDT, Ralf: Einbettung von Betriebsrisiken in die unternehmensweite Risikosteuerung. In: *Betriebswirtschaftliche Blätter* 7 (2001), Juli, S. 322–326
- Klugman u. a. 1998** KLUGMAN, Stuart A. ; PANJER, Harry H. ; WILLMOT, Gordon E.: *Loss Models – From Data to Decisions*. John Wiley & Sons, Inc, 1998
- Knight 1921** KNIGHT, Frank: *Risk, Uncertainty and Profit*. Boston : Hart, Schaffner & Marx; Houghton Mifflin Company, 1921
- Kommission der Europäischen Gemeinschaften 2004** KOMMISSION DER EUROPÄISCHEN GEMEINSCHAFTEN: *Vorschlag für RICHTLINIEN DES EUROPÄISCHEN PARLAMENTS UND DES RATES zur Neufassung der Richtlinie 2000/12/EG des Europäischen Parlaments und des Rates vom 20. März 2000 über die Aufnahme und Ausübung der Tätigkeit der Kreditinstitute und der Richtlinie 93/6/EWG des Rates vom 15. März 1993 über die angemessene Eigenkapitalausstattung von Wertpapierfirmen und Kreditinstituten*. Juli 2004
- Lavine 2000** LAVINE, Michael: What is Bayesian statistics and why everything else is wrong / Duke University. 2000. – Working Paper
- Leander 2002** LEANDER, Ellen: A moving target. In: *Risk* (2002), Dezember, S. 150–151
- Linstone und Turoff 1975** LINSTONE, H. A. ; TUROFF, M: *The Delphi Method*. New York : Addison-Wesley, 1975

- Longley-Cook 1962** LONGLEY-COOK, L. H.: An Introduction to Credibility Theory. In: *Proceedings of the Casualty Actuarial Society* XLIX (1962), S. 194–221
- Luhmann 1990** LUHMANN, Niklas: *Soziologie des Risikos*. de Gruyter, 1990
- MaH 1995** : *Verlautbarung I 4 – 42 – 3/86 vom 23.10.1995 zu Mindestanforderungen an das Betreiben von Handelsgeschäften der Kreditinstitute*. Oktober 1995
- Marshall 2000** MARSHALL, Christopher: *Measuring and Managing Operational Risks in Financial Institutions*. John Wiley & Sons, Inc, 2000
- Mathmann 2003** MATHMANN, Wolfgang: Operational Risk: Effektive Risikominderung durch Versicherungen. In: *Die Bank* 3 (2003), S. 164–167
- Metropolis u. a. 1953** METROPOLIS, Nicholas ; ROSENBLUTH, Arianna ; ROSENBLUTH, Marshall ; TELLER, August: Equation of State Calculations by Fast Computing Machines. In: *The Journal of Chemical Physics* 21 (1953), Juni, Nr. 6, S. 1087–1092
- Mißler-Behr 1993** MISSLER-BEHR, Magdalena: *Methoden der Szenarioanalyse*. Deutscher Universitätsverlag, 1993
- Norberg** NORBERG, Ragnar: *Credibility Theory*
- Ong 1998** ONG, Michael K.: On the quantification of operational risk. In: *Infinity World* October-December (1998)
- ORX Association 2004** ORX ASSOCIATION: *ORX Reporting Standards – An ORX Members’ Guide to Operational Risk Event/Loss Reporting*. Februar 2004
- Perrow 1984** PERROW, Charles: *Normal Accidents – Living with High-Risk Technologies*. Princeton University Press, 1984
- Pritsker 1996** PRITSKER, Matthew: Evaluating Value-at-Risk Methodologies: Accuracy versus Computational Time / Wharton School Center for Financial Institutions, University of Pennsylvania. November 1996 (96-48). – Working Paper
- Reason 1997** REASON, James: *Managing the Risks of Organizational Accidents*. Ashgate, 1997
- Reynolds und Syer 2002** REYNOLDS, Diane ; SYER, David: Mark to Future and Operational Risk. In: *Algo Research Quarterly* 5 (2002), Nr. 2, S. 39–52
- Risk Books 2003** RISK BOOKS (Hrsg.): *Advances in Operational Risk*. Risk Books, 2003

- RMA u. a. 1999** RMA ; BRITISH BANKERS' ASSOCIATION ; ISDA ; PRICEWATERHOUSECOOPERS: *Operational Risk – the next frontier*. 1999
- Roehr 2002** ROEHR, Ancus: Modelling Operational Losses. In: *Algo Research Quarterly* 5 (2002), Nr. 2, S. 53–64
- Samad-Kahn 2002** SAMAD-KAHN, Ali: How to Categorize Operational Losses? Applying Principles as Opposed to Rules / OpRisk Analytics LLC. 2002. – Working Paper
- Stauffer u. a. 1993** STAUFFER, Dietrich ; HEHL, Friedrich ; ITO, Nobuyasu: *Computer Simulation and Computer Algebra*. Springer Verlag, Berlin, 1993
- Stögbauer 2002** STÖGBAUER, Christian: *Miss es oder vergiss es! Quantitative Operational-Risk-Modellierung*. S. 179–204. In: ELLER, Roland (Hrsg.) ; GRUBER, Walter (Hrsg.) ; REIF, Markus (Hrsg.): *Handbuch operationelle Risiken*, Schäffer-Poeschel, 2002
- Stocker u. a. 2001** STOCKER, Georg ; NAUMANN, Mathias ; BUHR, Reinhard ; KIND, Ralf ; SCHWERTL, Markus: Qualitatives und quantitatives Controlling und Management von Operational Risk – Entwicklung eines Betriebsrisikocontrollings in der Bayerischen Landesbank. In: *Zeitschrift für das gesamte Kreditwesen* 12 (2001), S. 677–687
- van den Brink 2002** VAN DEN BRINK, Gerrit J.: *Operational Risk*. Palgrave, 2002
- Wurm 2001** WURM, Stephan: Die Anwendung von Elastizitäten bei der Quantifizierung operationeller Risiken. In: *Die Bank* 8 (2001), S. 598–600

Lebenslauf

Schulbildung

1981–1985 Katholische Grundschule Köln-Brück

1985–1989 Heinrich-Heine-Gymnasium Köln

1989–1994 Albertus-Magnus-Gymnasium Bensberg

Studium

1994–2002 Studium der Physik an der Universität zu Köln

1995–2000 Studium der Betriebswirtschaftslehre an der Universität zu Köln

2003–2007 Promotion in Statistik an der Ludwig-Maximilians-Universität München und am Center for Financial Studies in Frankfurt/Main bei Prof. Stefan Mittnik

Beruf

2000–2002 Berater bei der POM Prof. Tempelmeier GmbH

2002 Wissenschaftlicher Mitarbeiter am Institut für Theoretische Physik an der Universität zu Köln

2003–2005 Doktorand bei der DZ BANK AG

2005–2006 Berater bei der Capgemini Deutschland GmbH

seit 2006 Berater bei Roland Berger Strategy Consultants

Hiermit erkläre ich, dass die Dissertation selbständig und ohne unerlaubte Beihilfe angefertigt habe. Es wurden keine anderen als die angegebenen Hilfsmittel verwendet. Alle Zitate wurden als solche kenntlich gemacht.

Diese Arbeit wurde in dieser oder einer ähnlichen Form noch nicht veröffentlicht. Sie wurde weder ganz noch in Teilen einer anderen Prüfungskommission zur Begutachtung vorgelegt.

Weiterhin erkläre ich, dass ich mich noch nie anderweitig einer Doktorprüfung unterzogen habe.

Köln, den 10.04.2007